

ANALISIS KOMPARASI ARSITEKTUR EFFICIENTNETV2-S DAN RESNET50 DALAM KLASIFIKASI JENIS DAN TINGKAT KEPARAHAN PENYAKIT DAUN PADI

Muhammad Fathi Farhat, Sutan Faisal, Iman Sanjaya, Ahmad Fauzi, Kiki Ahmad Baihaqi

Teknik Informatika, Fakultas Ilmu Komputer, Universitas Buana Perjuangan Karawang

Jalan Ronggo Waluyo Sirnabaya, Karawang, Jawa Barat, Indonesia

if22.muhammadfarhat@mhs.ubpkarawang.ac.id

ABSTRAK

Padi merupakan komoditas pangan strategis, namun produksinya kerap terancam oleh penyakit daun. Identifikasi penyakit secara konvensional seringkali tidak efisien dan subjektif, sementara model deteksi otomatis yang ada umumnya berat secara komputasi dan belum terintegrasi dengan penentuan tingkat keparahan. Penelitian ini bertujuan membandingkan kinerja arsitektur EfficientNetV2-S dan ResNet50 untuk klasifikasi jenis penyakit daun padi, serta menguji algoritma OpenCV dalam mengestimasi tingkat keparahannya. Sebanyak 2.569 citra daun diproses dengan metode CLAHE dan augmentasi. Data tersebut dilatih menggunakan arsitektur *Deep Learning*, sedangkan segmentasi area infeksi dihitung melalui ruang warna HSV pada OpenCV. Hasil pengujian menunjukkan EfficientNetV2-S lebih unggul dengan akurasi 98% dan galat validasi 0,0414, dibandingkan ResNet50 yang mencapai akurasi 97% dan galat 0,0853. Selain itu, modul OpenCV berhasil mengkalkulasi rasio infeksi sesuai standar keparahan IRRI. Secara keseluruhan, model hibrida EfficientNetV2-S terbukti paling optimal dan berhasil diintegrasikan ke dalam purwarupa aplikasi *web*.

Kata kunci : *computer vision, deep learning, efficientnetv2-s, opencv, penyakit padi, resnet50*

1. PENDAHULUAN

Padi (*Oryza sativa* L.) merupakan komoditas pangan strategis yang menjadi pilar utama ketahanan pangan di Indonesia. Namun, pemenuhan kebutuhan beras saat ini menghadapi tantangan serius berupa fluktuasi produksi yang salah satunya disebabkan oleh faktor biotik, yaitu serangan Organisme Pengganggu Tumbuhan (OPT) [1], [2].

Laporan *International Rice Research Institute* (IRRI) mencatat bahwa secara global, petani kehilangan rata-rata 37% hasil panen setiap tahun akibat hama dan penyakit, dengan penyakit utama seperti *Rice Blast*, *Brown Spot*, dan *Bacterial Leaf Blight* [3].

Selama ini, metode identifikasi penyakit secara konvensional yang mengandalkan pengamatan visual pakar berjalan tidak efisien, cenderung subjektif, dan sering terlambat ditangani karena terbatasnya penyuluh pertanian di lapangan.

Permasalahan utama saat ini adalah meskipun teknologi *Computer Vision* dan *Deep Learning* seperti arsitektur ResNet50 mampu memberikan akurasi deteksi penyakit yang sangat tinggi hingga 99,75% [4], [5], model standar industri tersebut memiliki kompleksitas komputasi yang masif (sekitar 25 juta parameter). Hal ini menjadikannya sangat berat dan kurang relevan jika ditanamkan pada perangkat *mobile* milik petani yang berspesifikasi terbatas [6]. Selain itu, terdapat kesenjangan (*gap*) fitur yang krusial, di mana mayoritas studi hanya berfokus pada klasifikasi jenis penyakit tanpa mengintegrasikannya dengan estimasi tingkat keparahannya (*severity grading*). Padahal, informasi tingkat keparahan infeksi sangat

menentukan dosis pestisida yang tepat guna mencegah resistensi patogen [9], [10].

Sebagai rencana penyelesaian masalah, penelitian ini mengusulkan pendekatan sistem diagnosis hibrida yang ringan dan terintegrasi. Untuk mengatasi beban komputasi klasifikasi penyakit, diusulkan penggunaan arsitektur CNN generasi terbaru yang berorientasi pada *Green AI*, yakni EfficientNetV2-S, yang terbukti secara teoritis memiliki efisiensi jumlah parameter dan kecepatan pelatihan yang lebih unggul dari generasi sebelumnya [7], [8].

Sementara itu, untuk menyelesaikan masalah ketiadaan fitur estimasi keparahan penyakit tanpa membebani komputasi AI, diusulkan penerapan algoritma pengolahan citra klasik memanfaatkan pustaka OpenCV pada ruang warna HSV untuk mengkalkulasi area lesi secara presisi.

Tujuan utama dari penelitian ini adalah untuk mengukur dan membandingkan kinerja arsitektur EfficientNetV2-S dan ResNet50 secara langsung (*head-to-head*) dalam mengklasifikasikan jenis penyakit daun padi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Di samping itu, penelitian ini juga bertujuan menguji keandalan algoritma hibrida (CNN dan OpenCV) dalam menentukan tingkat keparahan penyakit secara otomatis. Hasil dari penelitian ini diharapkan dapat ditarik rekomendasi terbaik mengenai arsitektur *Deep Learning* yang memiliki keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi sebagai landasan pengembangan aplikasi *smart farming* di lapangan.

2. TINJAUAN PUSTAKA

2.1. Tanaman Padi dan Patologi

Kesehatan organ daun pada fase vegetatif dan reproduktif tanaman sangat krusial, mengingat daun bendera (*flag leaf*) berfungsi sebagai "dapur" fotosintesis utama yang menyuplai karbohidrat untuk proses pengisian bulir padi [6].

Adanya gangguan fisik pada daun akibat lesi penyakit akan menurunkan laju fotosintesis yang secara langsung berkorelasi pada penurunan kualitas maupun kuantitas hasil panen (*yield loss*). Penelitian ini memfokuskan klasifikasi pada tiga jenis penyakit destruktif. Penyakit *Rice Blast* (*Pyricularia oryzae*) merupakan penyakit mematikan yang ditandai dengan lesi berbentuk belah ketupat (*spindle-shaped*) berpusat abu-abu nekrotik, di mana sporanya dapat menyebar secara sangat cepat melalui udara [11].

Penyakit *Brown Spot* (*Bipolaris oryzae*) memunculkan bercak oval coklat berbingkai kuning (*chlorotic halo*) yang kerap muncul sebagai respons tanaman terhadap stres kekeringan dan defisiensi nutrisi tanah [12].

Sementara itu, penyakit *Bacterial Leaf Blight* (*Xanthomonas oryzae*) adalah penyakit vaskular yang menyumbat saluran xilem daun, menghambat transportasi air, sehingga memicu gejala layu berupa lesi memanjang berwarna pucat keabuan dari tepi daun [13].

2.2. Computer Vision dan Deep Learning

Computer Vision merupakan cabang kecerdasan buatan yang memungkinkan mesin untuk "melihat", menganalisis, dan mengekstrak makna dari citra digital. Jika pengolahan citra (*image processing*) tradisional hanya sebatas memanipulasi sinyal gambar, *Computer Vision* berupaya memahami konteks objek secara instan. Tantangan utamanya ketika diterapkan di lahan pertanian adalah mengatasi anomali visual pencahayaan (*low-light* atau *over-exposure*) serta oklusi latar belakang [14].

Salah satu penerapannya adalah estimasi tingkat keparahan (*disease severity estimation*). Pendekatan hibrida mengkombinasikan klasifikasi cerdas dengan teknik segmentasi warna (seperti *thresholding*) untuk mengukur area lesi secara terukur dan matematis [15]. Formulasi kalkulasi persentase keparahan (\$s\$) ditunjukkan pada persamaan (1).

$$s = \frac{\sum_{(x,y) \in I(x,y)} 1}{\sum_{(x,y) \in I(x,y)} 1} \times 100\% \quad (1)$$

Sebagai otak dari sistem pengenalan, *Deep Learning* mengatasi keterbatasan mesin komputasi tradisional dengan kemampuannya mengekstraksi fitur visual secara otomatis (*Automatic Feature Extraction*) secara *end-to-end* tanpa perlu intervensi pakar [16].

Model ini memanfaatkan *Convolutional Neural Network* (CNN) yang beroperasi menggunakan prinsip *local receptive fields* dan *shared weights*. Operasi inti

CNN adalah konvolusi, di mana sebuah kernel matriks digeser mengelilingi citra *input* untuk menghasilkan peta fitur (*feature map*), seperti dirumuskan pada persamaan (2).


$$z(i,j) = \sum_m \sum_n I(i+m, j+n) \cdot K(m,n) + b(2)$$

Operasi ini akan diikuti oleh proses *Pooling* guna mereduksi dimensi spasial fitur sekaligus menjaga sifat *translation invariance*, serta menggunakan fungsi aktivasi *Rectified Linear Unit* (ReLU) untuk menciptakan non-linearitas model, memungkinkan jaringan mengenali konsep visual tingkat tinggi secara hierarkis [17].

2.3. Arsitektur ResNet50

ResNet50 (*Deep Residual Network*), yang diperkenalkan pada tahun 2015, merupakan arsitektur yang berhasil memecahkan fenomena *Vanishing Gradient* (hilangnya sinyal kesalahan gradien pada jaringan saraf yang sangat dalam) dengan mengusung mekanisme *Residual Learning*. Alih-alih memaksa lapisan untuk mempelajari pemetaan fungsi dasar secara utuh, blok ini diformulasikan dengan koneksi pintas (*skip connection* atau *identity mapping*) seperti yang tertera pada persamaan (3).

$$y = F(x) + x \quad (3)$$




Gambar 1. Arsitektur Residual Block pada ResNet50

Sesuai pada gambar 1, koneksi pintas ini bertindak layaknya "jalan tol" yang memuluskan aliran gradien dari lapisan terujung (*output*) kembali ke lapisan awal. Menggunakan struktur "Bottleneck" yang mereduksi dan memulihkan dimensi dengan matriks berukuran (1×1 , 3×3 , 1×1), arsitektur tangguh ResNet50 sering diakui sebagai *baseline* (standar emas) untuk mengekstraksi representasi fitur biologis kompleks [18].

2.4. Arsitektur EfficientNetV2-S

EfficientNetV2 merupakan wujud evolusi yang merespons tuntutan tren *Green AI*, di mana model dioptimasi tidak hanya untuk menaikkan akurasi tetapi juga meningkatkan kecepatan latihan (*training speed*) dan meminimalkan beban parameter komputasi [7].

Inovasi arsitektural utamanya adalah adopsi blok *Fused-MBConv*. Berbeda dari pendahulunya yang memecah proses konvolusi, *Fused-MBConv* menyatukan konvolusi titik dan kedalaman kembali menjadi operasi konvolusi tunggal guna mengurangi *overhead* pembacaan memori perangkat keras secara drastis dapat dilihat gambar 2.



Gambar 2. Struktur Fused-MBConv pada EfficientNetV2

EfficientNetV2 mengembangkan *Compound Scaling* yang dengan cerdas meningkatkan skala parameter jaringan secara simultan dan berimbang pada tiga dimensi utamanya: kedalaman jaringan (*depth* α), kelebaran *channel* (*width* β), dan ukuran resolusi citra (*resolution* γ), sebagaimana dinyatakan pada persamaan (4).

$$\text{depth} = \alpha^\phi, \quad \text{width} = \beta^\phi, \quad \text{resolution} = \gamma^\phi \quad (4)$$

Varian *Small* (V2-S) dipilih untuk menanggulangi kecenderungan model besar (misal Varian B6) yang rentan mengalami malfungsi *overfitting* saat dilatih pada kumpulan dataset yang bersifat terbatas [8].

Jaringan ini semakin efisien berkat mekanisme perhatian *Squeeze-and-Excitation* (SE) yang secara adaptif mengalibrasi ulang *channel* fitur, memfokuskan mesin hanya pada area bercak lesi dan mengabaikan distorsi latar belakang tanah atau gulma [19].

2.5. Evaluasi Kinerja Model

Metrik evaluasi klasifikasi tunggal seperti Akurasi tidaklah memadai dan berpotensi memberikan kesimpulan yang bias (*misleading*), khususnya pada dataset kelas yang imbalans atau tidak seimbang [20].

Sebagai kompensasinya, metrik *F1-Score* yang merupakan perpaduan rata-rata harmonik seimbang antara tingkat *Precision* dan tingkat *Recall* diterapkan secara ketat. Formulasi *F1-Score* didefinisikan pada persamaan (5).

$$F1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

Di ranah pertanian cerdas, memiliki nilai *Recall* yang tinggi memegang peran terpenting karena ini mengukur kemampuan krusial sistem dalam mendeteksi dan mencegah lolosnya tanaman yang sakit (*False Negative*). Kesalahan jenis ini jauh lebih berisiko sebab satu tanaman sakit yang gagal terdeteksi dapat bertindak sebagai inang yang meledakkan wabah gagal panen sekawasan.

2.6. Penelitian Terkait

Studi sebelumnya telah mendemonstrasikan kapabilitas arsitektur CNN dalam mendiagnosis kelainan daun. Guna menutupi titik buta (limitasi) dari penelitian terdahulu yang umumnya berfokus satu arah, riset ini membangun ekosistem diagnosis yang terintegrasi, dengan berlandaskan pada temuan beberapa penelitian kunci. Penelitian oleh Simhadri &

Kondaveeti [5] membuktikan bahwa penerapan *Transfer Learning* pada model seperti ResNet50, VGG16, dan InceptionV3 sangat efektif untuk klasifikasi daun padi, di mana ResNet50 sukses menghasilkan akurasi tertinggi dan paling stabil yang menyentuh angka 99,75%. Di sisi lain, Kumar dkk. [7] menyoroti aspek efisiensi komputasi dengan mengoptimalkan arsitektur EfficientNetV2. Studi mereka mengonfirmasi bahwa EfficientNetV2 mampu mempertahankan tingkat akurasi yang tinggi meskipun menggunakan jumlah parameter yang jauh lebih sedikit.


Selain ranah klasifikasi, kalkulasi persentase area kerusakan fisik atau tingkat keparahan (*severity*) daun juga telah dieksplorasi secara mendalam. Xu dkk. [15] memperkenalkan pendekatan hibrida yang terbukti andal, dengan menggabungkan deteksi YOLOv11 dan teknik segmentasi OpenCV untuk menghitung persentase infeksi sekaligus menentukan kelas keparahan penyakit.

Hal ini sejalan dengan penelitian Patil dkk. [9] yang berhasil merumuskan dan mengklasifikasikan standar skala penyakit dari *Grade 0* hingga *Grade 4* memanfaatkan arsitektur *Faster R-CNN*. Integrasi antara pengenalan cerdas dan komputasi piksel tersebut terbukti praktis ketika Reddy dkk. [21] mengembangkannya menjadi aplikasi berbasis *mobile* menggunakan CNN dan OpenCV, yang mampu mendeteksi persentase kerusakan daun secara *real-time* dengan stabil. Berpijak dari keseluruhan referensi tersebut, penelitian ini merangkai keunggulan akurasi dari EfficientNetV2-S maupun ResNet50 dengan utilitas ruang warna HSV dari OpenCV untuk menciptakan alur estimasi penyakit yang lebih presisi dan efisien di lapangan.

3. METODE PENELITIAN

3.1. Objek Penelitian

Penelitian ini berfokus pada sistem diagnosis penyakit daun padi yang mengintegrasikan klasifikasi *Deep Learning* dengan pengolahan citra digital untuk estimasi tingkat keparahan (*severity*). Sistem dirancang untuk membandingkan performa arsitektur ResNet50 dan EfficientNetV2-S dalam membedakan empat kondisi: *Rice Blast*, *Brown Spot*, *Bacterial Leaf Blight*, dan *Healthy*. Data bersumber dari Kaggle berjudul "*Rice Leaf Diseases Detection*" [22] pada gambar 3.



Gambar 3. Tampilan Dataset Penyakit Daun Padi pada Platform Kaggle


Dua kelas minor lainnya disaring dan dihapus guna meminimalisasi ketidakseimbangan data (*imbalance class*) dan mencegah kebingungan ekstraksi ciri akibat tumpang tindih (*overlapping*) fitur visual.

3.2. Alat dan Bahan Penelitian

Pelatihan model dieksekusi menggunakan perangkat keras laptop berspesifikasi prosesor Intel i5-12500H, RAM 16 GB, dan unit pengolah grafis NVIDIA RTX 3050. Ekosistem perangkat lunak dibangun di atas Windows 11 menggunakan Python 3.9.25. *Library* utama yang melibatkan mencakup TensorFlow-GPU 2.10.1 dan Keras untuk arsitektur *Deep Learning*, OpenCV untuk segmentasi citra, serta Scikit-Learn untuk evaluasi performa matematis. Antarmuka purwarupa sistem dibangun dengan *framework* Flask di sisi *backend* serta kombinasi HTML5, CSS3, dan JavaScript di sisi *frontend*.

3.3. Prosedur Penelitian

Prosedur pelaksanaan penelitian disusun secara hierarkis dan sistematis agar menghasilkan kerangka diagnosis yang tangguh dan presisi. Secara garis besar, metodologi pengembangan ini dirangkum dalam diagram alir (*flowchart*) yang divisualisasikan pada gambar 4.



Gambar 4. Diagram Alir (*Flowchart*) Prosedur Penelitian

3.4. Studi Literatur

Studi literatur difokuskan pada kajian literatur mengenai patologi penyakit utama padi dan *state-of-the-art* implementasi arsitektur CNN. Analisis diarahkan untuk mengidentifikasi *research gap*, yakni masih minimnya penelitian yang mengintegrasikan klasifikasi cerdas dengan estimasi *grading* kerusakan daun secara efisien dalam satu alur eksekusi.

3.5. Pengumpulan Data



Gambar 5. Contoh Dataset Asli Citra Daun Padi

Data sekunder yang terkumpul diseleksi untuk membuang citra berkualitas buruk (*noise* tinggi) maupun salah pelabelan. Dataset akhir berjumlah 2.569 citra, yang memuat variasi visual kondisi pencahayaan dan latar belakang lapangan pada gambar 5. Dataset ini dipartisi secara proporsional menjadi Data Latih (70%), Data Validasi (20%), dan Data Uji (10%).

3.6. Pra-pemrosesan Data

Citra *input* distandarisasi (*resizing*) menjadi ukuran 224 x 224 piksel agar kompatibel dengan model dasar ImageNet, lalu dinormalisasi nilai RGB-nya ke skala 0–1 guna mengakselerasi algoritma optimasi. Untuk mencegah model menghafal data (*overfitting*), teknik augmentasi spasial acak seperti rotasi, pembalikan horizontal (*flip*), dan *zoom* diaplikasikan melalui fungsi *ImageDataGenerator* hasil di sajikan pada visualisasi gambar 6.



Gambar 6. Visualisasi Hasil Augmentasi Data

3.7. Perancangan Model

Sistem mengadopsi pendekatan hibrida (*hybrid*) yang disusun dalam empat tahap pemrosesan:

- Validasi Objek:** Mengevaluasi ambang batas warna hijau citra; menolak masukan yang teridentifikasi bukan daun untuk menekan *false prediction*.
- Klasifikasi Penyakit:** Mengeksekusi inferensi dari model ResNet50 atau EfficientNetV2-S. Jika klasifikasi menghasilkan prediksi *Healthy* (Daun Sehat), proses dihentikan dengan nilai *severity* 0%.
- Estimasi Severitas:** Jika terdeteksi penyakit, algoritma OpenCV dijalankan dengan mentransformasi citra BGR ke HSV. Masker biner diterapkan melalui *thresholding* untuk memisahkan piksel lesi penyakit secara selektif.
- Grading:** Luas area lesi dibandingkan dengan total luas daun untuk memperoleh persentase keparahan. Nilai ini kemudian dipetakan ke dalam kategori *Grade* 0-3 mengikuti standar pedoman IRRI [23] pada tabel 1.

Tabel 1. Standarisasi Penentuan Tingkat Keparahannya

Grade	Tingkat Keparahannya	Rentang Kerusakan (Rasio)
0	Sehat (<i>Healthy</i>)	0%
1	Ringan (<i>Mild</i>)	0.1% – 10%
2	Sedang (<i>Moderate</i>)	10.1% – 25%
3	Berat (<i>Severe</i>)	> 25%

3.8. Pelatihan dan Validasi Model

Pelatihan jaringan dikonfigurasi dengan algoritma optimasi Adam dan fungsi kerugian *Categorical Cross-Entropy*. Demi mencegah *overfitting*, dipasang serangkaian protokol *Callbacks* otomatis, di antaranya: *ReduceLROnPlateau* untuk menurunkan *learning rate* jika akurasi statis, *EarlyStopping* guna menghentikan *epoch* lebih dini jika kerugian validasi tidak kunjung membaik, serta *ModelCheckpoint* untuk menyimpan hanya bobot model yang tervalidasi paling optimal.

3.9. Pengujian dan Evaluasi

Kinerja komparatif dari kedua arsitektur model diuji melawan *Test Set* dan dipetakan ke dalam *Confusion Matrix*. Evaluasi kuantitatif didasarkan pada perolehan metrik Akurasi, Presisi, *Recall*, dan *F1-Score*. Di luar kualitas tebakan, efisiensi praktis juga diperhitungkan dengan mencatat perbandingan lama iterasi pemrosesan (*training time*) dan beban ukuran penyimpanan akhir (*model size*).

3.10. Implementasi Sistem

Sebagai hasil luaran, algoritma hibrida yang paling unggul diintegrasikan ke dalam sebuah purwarupa aplikasi *web* menggunakan *framework* Flask. *Backend server* mengoordinasi inferensi CNN dan komputasi segmentasi OpenCV. Sisi interaksi antarmuka didukung pemanggilan asinkron AJAX yang memungkinkan pengguna menerima visualisasi tingkat keparahannya beserta *confidence score* secara langsung (*real-time*) tanpa perlu memuat ulang peramban.


4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan dan Evaluasi Model


Pelatihan dan pengujian model dieksekusi menggunakan bahasa pemrograman Python di lingkungan Anaconda dengan akselerasi GPU NVIDIA RTX 3050. Proses pelatihan pada kedua arsitektur (ResNet50 dan EfficientNetV2-S) dibatasi hingga maksimum 30 *epoch*. Mekanisme *EarlyStopping* diaktifkan untuk mencegah sistem terjebak pada proses menghafal *noise* (*overfitting*), sementara fungsi *ReduceLROnPlateau* mengoptimasi kecepatan adaptasi bobot jaringan.

Berdasarkan pelatihan pada gambar 7, model EfficientNetV2-S membuktikan efisiensi konvergensi yang jauh lebih cepat dan stabil. Laju pelatihan arsitektur ini secara otomatis dihentikan oleh *EarlyStopping* pada *epoch* ke-24 karena akurasi tidak

lagi menemukan ruang perbaikan, mencatatkan nilai tingkat galat (*validation loss*) terendah sebesar 0,0414. Model ResNet50 menyelesaikan seluruh siklus eksperimen hingga *epoch* ke-27 namun dengan pola riwayat fluktuasi *loss* yang cukup agresif di ronde-ronde awal. *Validation loss* terbaik yang diraih ResNet50 tertahan di angka 0,0853 dapat di lihat pada gambar 8.




Gambar 7. Grafik Accuracy dan Loss pada pelatihan model EfficientNetV2-S



Gambar 8. Grafik Accuracy dan Loss pada pelatihan model ResNet50


Demi memastikan kinerja yang objektif, inferensi model diuji melawan kumpulan 257 citra pada Data Uji tak terlihat (*unseen data*). Hasil ketepatan prediksi pada tiap-tiap titik diagnosis kelas divisualisasikan menggunakan *Confusion Matrix* gambar 9 dan 10.



Gambar 9. Confusion Matrix pengujian EfficientNetV2-S

Berdasarkan Gambar 9 dan 10, kedua arsitektur sukses besar dan sempurna dalam mengidentifikasi kelas *Healthy* (0 *False Positive*). Perbedaan ketangguhan baru terlihat saat menghadapi dua

penyakit dengan gejala awal yang sering tumpang tindih secara visual: *Brown Spot* dan *Leaf Blast*. Model ResNet50 mengalami sedikit kesulitan untuk menegaskan batas antar keduanya, yang berujung pada beberapa kasus keliru tebak (misklasifikasi). Sebaliknya, EfficientNetV2-S terbukti lebih andal mereduksi kesalahan berkat bantuan modul *Squeeze-and-Excitation* (SE) yang menajamkan fokus perhatian model pada karakteristik unik lesi patogen. Ringkasan perbandingan metrik kinerja terlampir pada tabel 2.



Gambar 10. Confusion Matrix pengujian ResNet50

Tabel 2. Hasil Komparasi Kinerja Pengujian Model

Metrik Evaluasi	EfficientNetV2-S	ResNet50
Akurasi Keseluruhan	98%	97%
<i>F1-Score</i> (Weighted)	0.98	0.97
Efisiensi Per Langkah	44ms/step	40ms/step

Merujuk pada tabel 2, EfficientNetV2-S tampil mendominasi secara absolut dengan Akurasi mencapai 98% dan harmonisasi *F1-Score* 0,98. Meskipun proses pelatihannya memakan waktu sedikit lebih lama di setiap langkah (44 milidetik per *step* berbanding 40 milidetik), *trade-off* ini sangat sepadan demi mendapatkan ketahanan prediksi yang hampir presisi sempurna. Karena keunggulan tersebut, arsitektur ini ditetapkan sebagai "otak utama" yang akan ditanamkan ke dalam purwarupa aplikasi diagnosis.

4.2. Hasil Estimasi Tingkat Keparahan Penyakit

Diagnosis jenis penyakit belumlah tuntas tanpa informasi derajat keparahannya. Sebagai fitur komplementer dari *Deep Learning*, sistem menyuntikkan algoritma segmentasi *Computer Vision* yang berpusat pada pustaka OpenCV. Alur komputasinya mengkonversi piksel citra RGB menjadi ruang warna HSV (*Hue, Saturation, Value*) agar kebal terhadap bayangan dan silau. Kalkulasi persentase keparahan dilakukan menggunakan persamaan matematika rasio kerusakan, dirumuskan pada persamaan (5):


$$s = \frac{\sum Plesi}{\sum Pdaun} \times 100\% \quad (5)$$

Komponen *s* melambangkan persentase tingkat keparahan. $\sum Plesi$ mewakili keseluruhan jumlah titik piksel warna lesi penyakit (seperti bercak coklat atau hitam), sedangkan $\sum Pdaun$ merupakan total titik piksel fisik organ daun secara keseluruhan.

Seperti diilustrasikan pada Gambar 9, teknik segmentasi dikerjakan secara berlapis dengan dua masker (*masking*). Masker pertama membedakan piksel entitas daun dari cengkeraman latar belakang lapangan. Di atas kanvas yang sama, masker lapis kedua menelusuri rentang warna anomali patogen untuk memblokir area lesi penyakit. Persentase irisan yang diperoleh akan merujuk kembali kepada tabel standarisasi IRR untuk memunculkan vonis *Grade* penyakit.

Hasil empiris mengkonfirmasi keandalan kalkulasi rasio piksel ini dalam menempatkan level penyakit dengan proporsional. Meski begitu, temuan di lapangan membuktikan model pemisahan berbasis warna murni ini memiliki batas toleransi (*error rate*). Secara berkala sistem masih terjebak *False Positive*, bilamana distorsi latar belakang tanah basah atau bayangan pekat memiliki kemiripan spektrum warna mutlak dengan warna dasar penyakit.

4.3. Implementasi Sistem Berbasis Web



Gambar 11. Tampilan antarmuka hasil diagnosis penyakit dan estimasi severity pada web

Pre-trained model EfficientNetV2-S hasil eksperimen dikemas bersama skrip *masking* OpenCV untuk memotori antarmuka sistem cerdas. Arsitekturnya mengandalkan *framework* Flask di sisi server (*Backend*) dan komunikasi AJAX asinkron di pihak antarmuka pengguna (*Frontend*). Petani diposisikan layaknya pengguna akhir (*end-user*) yang hanya dituntut untuk memuat gambar daun mereka pada dasbor peramban.

Begitu citra diterima, server seketika mengkoreografikan eksekusi hibrida. Halaman web segera bereaksi dengan memaparkan tiga *output* fundamental secara interaktif, yakni: nama spesifik patogen berikut probabilitas *confidence score*-nya, tingkatan IRRI *Grade* keparahan, serta panel proyektor *masking* biner (hitam-putih) yang mencitrakan posisi kerusakan anatomis daun secara transparan dapat di lihat pada gambar 11.

Demi menjaga sistem agar tetap anti-kritis, ditambahkan pula sebuah lapisan algoritma penyaringan kondisional (*Bypass*). Tatkala kecerdasan buatan menyimpulkan hasil *Healthy Rice Leaf* (Daun Sehat) sejak tahap permulaan, server secara paksa membatalkan sisa proses rutinitas segmentasi OpenCV. Seluruh rentang persentase dinonaktifkan menuju angka mutlak 0%. Langkah mitigasi ini efektif meredam kemungkinan vonis sakit secara keliru (*False Positive*) yang acap kali bersumber dari bias algoritma pembaca warna.

5. KESIMPULAN DAN SARAN

Penelitian ini menyimpulkan bahwa arsitektur EfficientNetV2-S memiliki kinerja yang lebih unggul dan efisien dibandingkan ResNet50 dalam klasifikasi penyakit daun padi, mencapai akurasi 98%, *F1-Score* 0,98, dan tingkat galat validasi 0,0414 tanpa mengalami *overfitting* berkat dukungan modul Fused-MBConv dan mekanisme atensi. Algoritma visi komputer berbasis segmentasi warna HSV terbukti mampu mengekstraksi area lesi dan mengestimasi rasio keparahan penyakit ke dalam skala *Grade* standar IRRI, di mana kerentanannya terhadap *false positive* akibat bias latar belakang berhasil diatasi secara efektif menggunakan logika hibrida pencegahan prediksi kelas sehat. Penyatuan proses ini melahirkan purwarupa aplikasi *web diagnosis end-to-end* yang praktis berbekal *framework* Flask.

Sebagai saran untuk pengembangan selanjutnya, direkomendasikan penambahan variasi dataset dari lingkungan persawahan ekstrem serta penggunaan teknik *Auto-thresholding* guna meningkatkan ketahanan algoritma OpenCV terhadap kondisi pencahayaan yang fluktuatif. Selain itu, pengembangan sistem agar mendukung fitur *Open-Set Recognition* dengan memanfaatkan ambang batas *confidence score* (misalnya < 70%) untuk menolak penyakit yang tidak dikenali, integrasi basis data rekomendasi penanganan standar Kementerian Pertanian, serta migrasi arsitektur ke platform perangkat seluler (*mobile*) menggunakan pustaka

seperti TensorFlow Lite sangat disarankan agar teknologi ini semakin utuh dan aplikatif bagi petani langsung di lapangan.

DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, "Luas panen dan produksi padi di Indonesia 2024 (Berita Resmi Statistik No. 12/02/Th. XXVII)," Jakarta, Indonesia, 2025. [Online]. Available: <https://www.bps.go.id/>
- [2] Balai Besar Peramalan Organisme Pengganggu Tumbuhan (BBPOPT), "Prakiraan Serangan OPT," Kementerian Pertanian Republik Indonesia, 2024.
- [3] International Rice Research Institute (IRRI), "Where rice pests and diseases do the most damage," *Rice Today*, 2023. [Online]. Available: <https://ricetoday.irri.org/>
- [4] D. E. Saputra *et al.*, "Implementasi Deep Learning Untuk Identifikasi Penyakit Melalui Daun Pada Tanaman Padi Menggunakan Metode Convolutional Neural Network."
- [5] C. G. Simhadri and H. K. Kondaveeti, "Automatic Recognition of Rice Leaf Diseases Using Transfer Learning," *Agronomy*, vol. 13, no. 4, Apr. 2023, doi: 10.3390/agronomy13040961.
- [6] P. Pai *et al.*, "Deep learning-based automatic diagnosis of rice leaf diseases using ensemble CNN models," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-13079-z.
- [7] P. Mohan Kumar, Ramavath Laxmi Bhargavi, Shaik Imran, and Mrs. J. Sowmya, "Rice Plant Disease Detection Using Efficient Net V2," *International Research Journal on Advanced Engineering Hub (IRJAEH)*, vol. 3, no. 01, pp. 31–51, Jan. 2025, doi: 10.47392/irjaeh.2025.0006.
- [8] A. C. Milano, "KLASIFIKASI PENYAKIT DAUN PADI MENGGUNAKAN MODEL DEEP LEARNING EFFICIENTNET-B6," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 1, Jan. 2024, doi: 10.23960/jitet.v12i1.3855.
- [9] R. R. Patil, S. Kumar, S. Chiwhane, R. Rani, and S. K. Pippal, "An Artificial-Intelligence-Based Novel Rice Grade Model for Severity Estimation of Rice Diseases," *Agriculture (Switzerland)*, vol. 13, no. 1, Jan. 2023, doi: 10.3390/agriculture13010047.
- [10] Mutiara Irmadhani, W. Syaifullah JS, and M. Idhom, "Complex-Valued Neural Network And Fuzzy Inference System For Image Diagnosis Of Rice Leaf Diseases," *Jurnal Riset Informatika*, vol. 7, no. 3, pp. 102–110, Jun. 2025, doi: 10.34288/jri.v7i3.370.
- [11] M. Poornima, "Convolutional Neural Networks Based Paddy Leaf Disease Detection," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, no. 4, pp. 2991–

- 3000, Apr. 2024, doi: 10.22214/ijraset.2024.60546.
- [12] A. Shamshad, M. Rashid, A. Hameed, and H. M. I. Arshad, "Identification of biochemical indices for brown spot (*Bipolaris oryzae*) disease resistance in rice mutants and hybrids," *PLoS One*, vol. 19, no. 4 April, Apr. 2024, doi: 10.1371/journal.pone.0300760.
- [13] C. Hongo, S. Isono, G. Sigit, and E. Tamura, "Efficient Damage Assessment of Rice Bacterial Leaf Blight Disease in Agricultural Insurance Using UAV Data," *Agronomy*, vol. 14, no. 6, Jun. 2024, doi: 10.3390/agronomy14061328.
- [14] H. A. H. Gondal *et al.*, "Artificial Intelligence-Based Plant Disease Classification in Low-Light Environments," *Fractal and Fractional*, vol. 9, no. 11, Nov. 2025, doi: 10.3390/fractalfract9110691.
- [15] Y. X. Xu, X. H. Yu, Q. Yi, Q. Y. Zhang, and W. H. Su, "Dual-Phase Severity Grading of Strawberry Angular Leaf Spot Based on Improved YOLOv11 and OpenCV," *Plants*, vol. 14, no. 11, Jun. 2025, doi: 10.3390/plants14111656.
- [16] H. N. Ngugi, A. A. Akinyelu, and A. E. Ezugwu, "Machine Learning and Deep Learning for Crop Disease Diagnosis: Performance Analysis and Review," Dec. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/agronomy14123001.
- [17] M. Sadhasivam, M. K. Geetha, and J. G. M. Britto, "Efficient deep learning architecture for the classification of diseased plant leaves," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 33, no. 1, pp. 198–206, Jan. 2024, doi: 10.11591/ijeecs.v33.i1.pp198-206.
- [18] sairam N. sunandhan, S. Suthanthiraa, and M. S. Uma, "Eye Disease Classification by Advanced Deep Transfer Learning System Using Resnet50 & Xception," Jul. 15, 2025. doi: 10.21203/rs.3.rs-7106561/v1.
- [19] S. Karthikeyan, R. Charan, S. Narayanan, and L. Jani Anbarasi, "Enhanced plant disease classification with attention-based convolutional neural network using squeeze and excitation mechanism," *Front. Artif. Intell.*, vol. 8, 2025, doi: 10.3389/frai.2025.1640549.
- [20] A. O. Adegbenjo and M. O. Ngadi, "Handling the Imbalanced Problem in Agri-Food Data Analysis," Oct. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/foods13203300.
- [21] B. Ramana Reddy, G. Kalnoor, M. Devashish, and P. Sai Karthik Reddy, "Deep Learning Based Mobile Application for Automated Plant Disease Detection," *IEEE Access*, vol. 13, pp. 107917–107925, 2025, doi: 10.1109/ACCESS.2025.3581099.
- [22] Anshul, "Rice Leaf Diseases Detection Dataset," *Kaggle*, 2024. [Online]. Available: <https://www.kaggle.com/datasets/anshulm257/rice-disease-dataset>.
- [23] International Rice Research Institute (IRRI), "Standard Evaluation System for Rice (SES)," 2025