



# Identifikasi Penyakit Padi Berdasarkan Citra Daun Menggunakan Arsitektur Convolutional Neural Network Kustom

Andre Gunawan Polontalo\*, Mohamad Ilyas Abas, Widya Eka Pranata

Fakultas Sains dan Ilmu Komputer, Program Studi Ilmu Komputer, Universitas Muhammadiyah Gorontalo, Gorontalo, Indonesia

Email: <sup>1</sup>[darkandlight.00000@gmail.com](mailto:darkandlight.00000@gmail.com), <sup>2</sup>[ilyasabas@umgo.ac.id](mailto:ilyasabas@umgo.ac.id), <sup>3</sup>[widyapranata@umgo.ac.id](mailto:widyapranata@umgo.ac.id)

Email Penulis Korespondensi: [darkandlight.00000@gmail.com](mailto:darkandlight.00000@gmail.com)

**Abstrak-**Produksi padi di Indonesia sering menurun akibat serangan penyakit daun yang sulit dideteksi secara dini dengan cara konvensional. Penelitian ini bertujuan mengidentifikasi penyakit daun padi berdasarkan citra daun menggunakan Convolutional Neural Network (CNN). Data penelitian diperoleh dari repositori daring (Kaggle) yang memuat citra daun padi berlabel dalam beberapa kelas penyakit. Model CNN kustom dirancang dan dilatih setelah dilakukan pra-pemrosesan citra (resize menjadi  $224 \times 224$  piksel), normalisasi, serta augmentasi data untuk mengurangi overfitting. Pelatihan dilakukan di lingkungan Google Colab menggunakan TensorFlow, dengan pembagian data 70:30, 80:20, dan 90:10 untuk menganalisis performa. Hasil terbaik menunjukkan akurasi pelatihan 83,02% dan akurasi pengujian 77,33%. Selain itu, model dibandingkan dengan beberapa arsitektur populer yang banyak digunakan dalam literatur, seperti ResNet50, VGG16, dan EfficientNetB0. Hasil penelitian menunjukkan bahwa model CNN kustom mampu memberikan kinerja klasifikasi kompetitif untuk deteksi dini penyakit daun padi, sehingga berpotensi menjadi sistem pendukung keputusan bagi petani dalam pengendalian penyakit secara cepat dan efisien.

**Kata Kunci:** Convolutional Neural Network; Penyakit Daun Padi; Citra Daun; Deep Learning; Pertanian Digital.

**Abstract-**Rice production in Indonesia often declines due to leaf diseases that are difficult to detect early using conventional methods. This study aims to identify rice leaf diseases based on leaf images using a Convolutional Neural Network (CNN). The dataset was obtained from an online repository (Kaggle) containing labeled images of rice leaves across several disease categories. A custom CNN model was designed and trained after applying image preprocessing (resizing to  $224 \times 224$  pixels), normalization, and data augmentation to reduce overfitting. The training was conducted in the Google Colab environment using TensorFlow with train-test splits of 70:30, 80:20, and 90:10 to analyze model performance. The best result achieved a training accuracy of 83.02% and a testing accuracy of 77.33%. Furthermore, the model was compared with several widely used architectures in the literature, including ResNet50, VGG16, and EfficientNetB0. The findings indicate that the proposed custom CNN model provides competitive classification performance for early detection of rice leaf diseases and has the potential to serve as a decision-support system for farmers in rapid and efficient disease management.

**Keyword:** Convolutional Neural Network; Rice Leaf Disease; Leaf Image; Deep Learning; Digital Agriculture

## 1. PENDAHULUAN

Indonesia sebagai negara agraris dengan iklim tropis memiliki ketergantungan tinggi terhadap produksi padi sebagai sumber pangan utama. Namun, fluktuasi iklim, perubahan pola curah hujan, serta meningkatnya serangan penyakit daun seperti hawar daun bakteri, blas, dan bercak cokelat telah menyebabkan penurunan hasil panen yang signifikan di berbagai wilayah. Kondisi ini mengancam ketahanan pangan nasional dan ekonomi masyarakat tani. Upaya peningkatan produktivitas dan mitigasi kehilangan hasil panen memerlukan penerapan teknologi pertanian cerdas yang mampu mendeteksi penyakit tanaman secara cepat, akurat, dan efisien [1], [2], [3].

Identifikasi penyakit padi secara konvensional umumnya masih mengandalkan inspeksi visual oleh pakar lapang. Metode ini bergantung pada keahlian manusia dan bersifat subjektif, sehingga tidak efisien untuk diterapkan pada area luas dengan jumlah sampel besar. Untuk mengatasi keterbatasan tersebut, berbagai penelitian mengusulkan pendekatan otomatis berbasis pengolahan citra digital dan pembelajaran mesin. Salah satu pendekatan yang berkembang pesat adalah Convolutional Neural Network (CNN), yang terbukti unggul dalam tugas klasifikasi citra termasuk pada bidang pertanian digital [4], [5], [6].

Beberapa penelitian sebelumnya telah membuktikan efektivitas CNN untuk deteksi penyakit padi. Sheila et al [4], menggunakan arsitektur CNN sederhana untuk mendeteksi tiga jenis penyakit daun padi dan memperoleh akurasi 82%. Agustina et al [5] mengimplementasikan DenseNet-121 dengan augmentasi data dan mencapai akurasi 88,4%, sedangkan Milano [5] menggunakan EfficientNet-B6 untuk klasifikasi enam kelas penyakit dengan akurasi mencapai 90%. Walaupun hasil tersebut menunjukkan potensi CNN, sebagian besar studi hanya menggunakan transfer learning dengan model pra-terlatih, bukan merancang arsitektur CNN yang dioptimalkan untuk karakteristik dataset padi secara spesifik [7], [8], [9].

Selain itu, dataset yang digunakan pada sebagian besar penelitian bersifat terkurasi, dengan latar belakang dan pencehayaan homogen, sehingga model yang dihasilkan sering gagal beradaptasi dengan kondisi lapang yang bervariasi. Penelitian oleh Rachman et al [10] misalnya, menggunakan dataset yang terbatas pada kondisi pencehayaan terkendali, sehingga kemampuan generalisasi model terhadap citra nyata menjadi rendah. Kesenjangan ini menandakan perlunya model CNN kustom yang dirancang dan dilatih khusus pada dataset yang merepresentasikan variasi nyata di lapangan, dengan penerapan teknik augmentasi yang efektif untuk memperluas keragaman data pelatihan [11], [12].

Seiring kemajuan teknologi *deep learning*, berbagai penelitian juga berfokus pada perbandingan arsitektur populer seperti ResNet, VGG, dan EfficientNet dalam konteks klasifikasi citra pertanian. Namun, setiap arsitektur memiliki trade-off antara akurasi dan efisiensi komputasi. ResNet dikenal stabil namun memerlukan waktu pelatihan panjang, sedangkan



EfficientNet lebih efisien tetapi sensitif terhadap konfigurasi hiperparameter. Berdasarkan kondisi tersebut, penelitian ini berupaya mengembangkan arsitektur CNN ringan namun tetap akurat untuk mendeteksi penyakit daun padi, sekaligus menganalisis pengaruh parameter pelatihan seperti ukuran citra, jumlah epoch, dan pembagian data terhadap performa model [5], [7].

Dalam kajian arsitektur, penelitian ini merancang model CNN kustom dan melakukan uji komparatif terhadap beberapa arsitektur populer untuk mengevaluasi trade-off akurasi versus efisiensi komputasi. Rancangan eksperimen mencakup pengaturan hyperparameter (optimizer, learning rate, batch size), pembagian data latih/validasi/uji, serta penerapan early stopping dan pemantauan metrik seperti akurasi, precision, recall, dan F1-score per kelas [9], [13].

Hasil awal dari studi komparatif pada literatur mengindikasikan bahwa ukuran citra dan konfigurasi epoch memengaruhi performa secara signifikan: resolusi yang lebih tinggi cenderung memberikan representasi fitur yang lebih kaya namun meningkatkan kebutuhan komputasi, sedangkan augmentasi dan pembagian dataset yang tepat membantu mengurangi bias dan meningkatkan robustness model. Oleh karena itu penelitian ini menempatkan fokus analitis pada pengaruh ukuran citra, teknik augmentasi, dan skema pembagian data terhadap metrik evaluasi [14], [15].

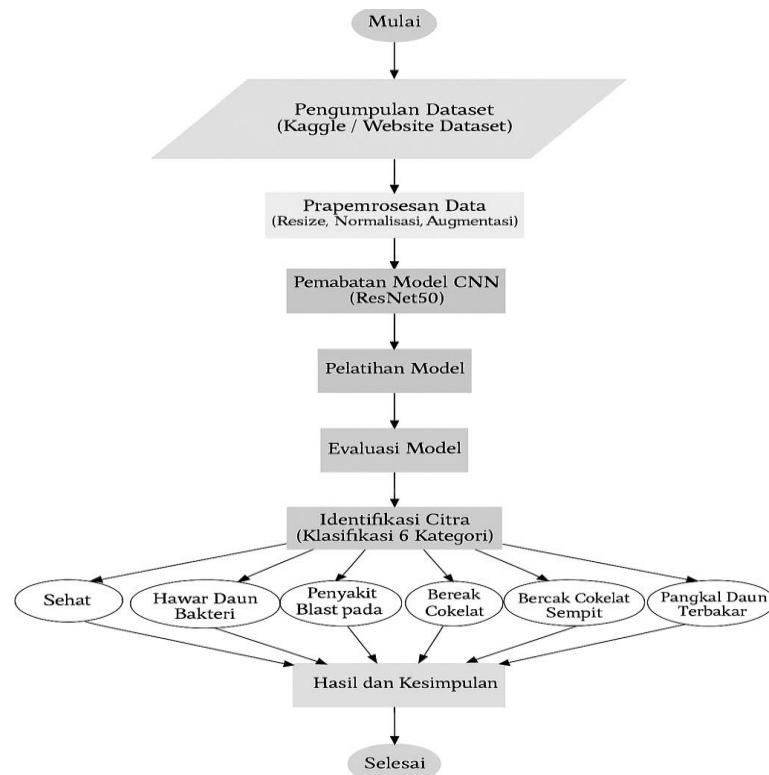
Meskipun hasil penelitian terdahulu memperlihatkan akurasi tinggi pada dataset terkuras, masalah generalisasi ke citra lapang (pencahayaan tidak terkontrol, latar belakang bervariasi, kerusakan mekanis) masih menjadi tantangan. Selain itu kebutuhan untuk model ringan agar dapat di-deploy pada perangkat mobile atau edge juga tercatat sebagai gap riset yang perlu ditangani. Penelitian ini berusaha menjawab gap tersebut dengan (i) mengembangkan model kustom yang dioptimasi untuk dataset tersedia, (ii) menganalisis efek pre-processing dan augmentasi secara sistematis, dan (iii) membandingkan model kustom dengan arsitektur populer untuk mengevaluasi kompromi akurasi vs. efisiensi. Dengan demikian, tujuan penelitian ini adalah mengembangkan model Convolutional Neural Network (CNN) kustom untuk mengidentifikasi enam jenis penyakit daun padi berdasarkan citra, serta menganalisis performanya dibandingkan dengan arsitektur populer seperti ResNet50, VGG16, dan EfficientNetB0 guna memperoleh model yang akurat dan efisien untuk diterapkan pada sistem pertanian cerdas [16], [17].

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan utama yang ditunjukkan pada Gambar 1. Setiap tahap mencakup identifikasi masalah, pengumpulan data, prapemrosesan citra, perancangan model Convolutional Neural Network (CNN), pelatihan dan evaluasi model, serta proses klasifikasi citra daun padi. Seluruh proses diimplementasikan menggunakan bahasa pemrograman Python dengan pustaka *TensorFlow* dan *Keras* pada lingkungan *Google Colab* untuk memanfaatkan sumber daya GPU [4], [5].

Tahapan-tahapan dalam penelitian ini secara umum ditampilkan pada Gambar 1.



**Gambar 1.** Diagram Alur



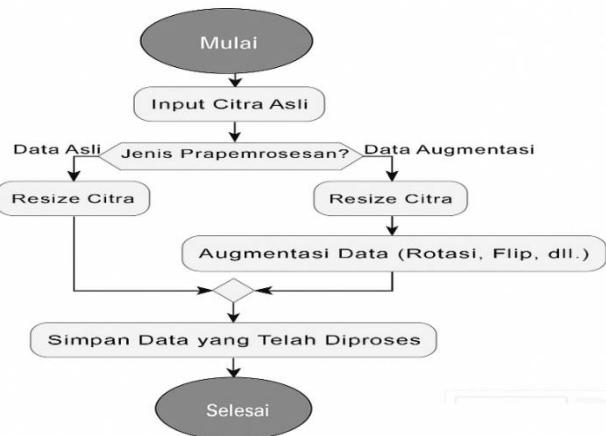
Berdasarkan Gambar 1, proses penelitian diawali dengan pengumpulan dataset dari sumber daring seperti Kaggle, yang memuat citra daun padi dalam enam kategori. Tahap berikutnya adalah pra-pemrosesan data, meliputi *resize*, normalisasi, dan augmentasi untuk meningkatkan variasi citra. Setelah itu, dilakukan pembuatan dan pelatihan model CNN menggunakan arsitektur ResNet50 yang dioptimalkan dengan pengaturan *hyperparameter* tertentu. Model kemudian dievaluasi berdasarkan metrik akurasi dan loss. Tahap akhir adalah identifikasi citra daun padi ke dalam enam kelas: sehat, hawar daun bakteri, penyakit blas, bercak cokelat, bercak cokelat sempit, dan pangkal daun terbakar. Hasil klasifikasi tersebut menjadi dasar penarikan hasil dan kesimpulan penelitian [7], [9].

## 2.2 Pengumpulan dan Prapemrosesan Data

Dataset yang digunakan diperoleh dari platform *Kaggle* yang berisi 2.628 citra daun padi, masing-masing mewakili enam kategori: *healthy*, *bacterial leaf blight*, *leaf blast*, *brown spot*, *narrow brown spot*, dan *leaf scald*. Setiap citra memiliki format JPEG dengan resolusi bervariasi dan diambil dalam kondisi pencahayaan serta latar belakang yang beragam. Untuk menjaga konsistensi, semua citra diubah ukurannya menjadi  $224 \times 224$  piksel [10], [11], [18].

Pra-pemrosesan dilakukan untuk memperbaiki kualitas citra dan mempercepat proses pelatihan. Prosedur ini meliputi normalisasi piksel ke rentang  $[0,1]$ , konversi ruang warna RGB, serta augmentasi data berupa rotasi acak (15–30°), *horizontal flip*, variasi kecerahan  $\pm 20\%$ , *zoom range* 0,2, dan penambahan *Gaussian noise*. Proses augmentasi ini bertujuan meningkatkan variasi data pelatihan dan mengurangi risiko *overfitting* [5], [7].

Setelah augmentasi, dataset dibagi menjadi tiga subset dengan rasio 70% data latih, 20% data validasi, dan 10% data uji. Setiap subset memastikan distribusi kelas yang seimbang untuk menjaga stabilitas hasil pelatihan. Skema pembagian data dan tahapan augmentasi divisualisasikan dalam diagram alir pada Gambar 2 [9].



**Gambar 2.** Diagram proses prapemrosesan

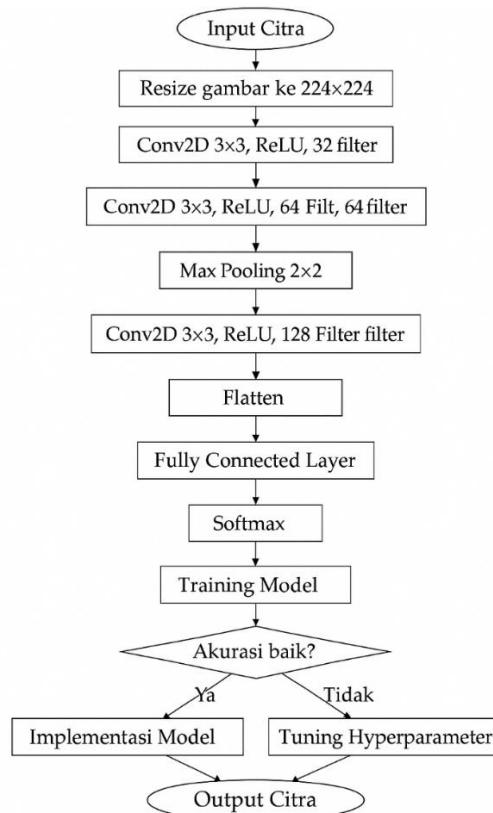
Berdasarkan Gambar 2 menunjukkan tahapan prapemrosesan citra yang dimulai dari proses *input* citra asli. Setelah data citra dimasukkan, dilakukan pemilihan jenis prapemrosesan antara data asli dan data augmentasi. Jika menggunakan data asli, citra langsung mengalami proses *resize* untuk menyeragamkan ukuran gambar, sedangkan jika menggunakan data augmentasi, citra akan di-*resize* terlebih dahulu kemudian dilakukan proses augmentasi data seperti rotasi, *flip*, atau transformasi lainnya. Seluruh data hasil prapemrosesan kemudian disimpan sebagai data siap olah pada tahap selanjutnya.

## 2.3 Arsitektur Model CNN

Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini merupakan model kustom yang terdiri atas empat blok konvolusi dan *max-pooling* bertingkat, diikuti oleh dua lapisan *fully connected* dan satu lapisan *output* dengan fungsi aktivasi Softmax. Setiap blok konvolusi menggunakan filter berukuran  $3 \times 3$  dengan fungsi aktivasi ReLU (*Rectified Linear Unit*), sementara *max-pooling* memiliki ukuran kernel  $2 \times 2$  untuk mereduksi dimensi spasial dan mengontrol kompleksitas komputasi. Jumlah filter pada setiap blok konvolusi ditetapkan secara bertingkat, yaitu 32, 64, 128, dan 256 filter, untuk menangkap pola visual dengan tingkat kedetailan yang semakin tinggi pada setiap lapisan. Untuk mencegah *overfitting*, diterapkan lapisan Dropout sebesar 0,5 pada lapisan *fully connected*. Parameter bobot diinisialisasi menggunakan metode *He Normal initialization*, sedangkan *Batch Normalization* diterapkan setelah setiap operasi konvolusi untuk mempercepat konvergensi pelatihan dan menjaga stabilitas distribusi aktivasi. Lapisan-lapisan CNN ini dirancang untuk mengekstraksi fitur visual yang merepresentasikan tekstur, pola, serta bentuk gejala penyakit daun padi, seperti bercak cokelat, lesi memanjang, atau perubahan warna. Lapisan *output* menggunakan fungsi aktivasi Softmax dengan enam neuron yang mewakili enam kelas citra, yaitu: daun sehat, hawar daun bakteri, blas, bercak cokelat, bercak cokelat sempit, dan pangkal daun terbakar [8], [9].

Lapisan-lapisan CNN dirancang untuk mengekstraksi fitur visual yang merepresentasikan tekstur, pola, dan bentuk gejala penyakit pada daun padi. Parameter bobot diinisialisasi menggunakan metode *He Normal*, dan normalisasi batch diterapkan setelah setiap konvolusi untuk mempercepat konvergensi pelatihan. Rancangan arsitektur ini diilustrasikan pada Gambar 3 [13].

Arsitektur lengkap dari model CNN dapat dilihat pada Gambar 3.



**Gambar 3.** Arsitektur Model CNN

Gambar 3 menunjukkan alur kerja pelatihan model CNN yang dimulai dari input citra, kemudian citra di-*resize* ke ukuran  $224 \times 224$  piksel. Setelah itu dilakukan proses normalisasi dan augmentasi untuk menyeimbangkan data pelatihan. Citra selanjutnya melewati beberapa lapisan konvolusi (Conv2D) dengan filter berukuran 32, 64, dan 128 serta fungsi aktivasi ReLU, disertai lapisan MaxPooling  $2 \times 2$  untuk mereduksi dimensi fitur. Hasil ekstraksi fitur kemudian diratakan melalui proses flatten dan dilanjutkan ke fully connected layer sebelum melewati lapisan softmax untuk klasifikasi. Tahap berikutnya adalah pelatihan model (training) dan evaluasi model untuk mengukur performa akurasi. Jika akurasi sudah baik, model akan dilanjutkan ke tahap implementasi, namun jika belum, dilakukan penyesuaian hyperparameter (tuning). Setelah model optimal, sistem digunakan untuk prediksi gambar baru, dan hasil akhirnya berupa output citra [16], [9].

#### 2.4 Proses Pelatihan dan Evaluasi Model

Model CNN dilatih menggunakan *optimizer Adam* dengan *learning rate* 0,001 dan *batch size* 32. Proses pelatihan dilakukan selama maksimum 50 *epoch* dengan penerapan *early stopping* berdasarkan metrik akurasi validasi. Fungsi *loss* yang digunakan adalah *categorical cross-entropy* karena penelitian ini bersifat klasifikasi multikelas [5], [7].

Evaluasi model mencakup beberapa metrik, yaitu akurasi, *precision*, *recall*, dan *F1-score* yang dihitung untuk setiap kelas. Selain itu, *confusion matrix* digunakan untuk mengidentifikasi pola kesalahan klasifikasi dan mengukur seberapa baik model membedakan antar kelas penyakit. Perhitungan metrik dilakukan menggunakan pustaka *scikit-learn* [13], [19].

Eksperimen dilakukan pada lingkungan *Google Colab* dengan GPU *Tesla T4*, RAM 12 GB, dan runtime Python 3.10. Hasil pelatihan direkam dalam bentuk grafik *loss* dan *accuracy* terhadap *epoch* untuk menilai stabilitas pelatihan. [14], [20].

#### 2.5 Proses Klasifikasi Citra Daun Padi

Tahapan klasifikasi citra daun padi dimulai dengan memasukkan citra uji ke dalam model CNN yang telah terlatih. Citra yang masuk melalui lapisan konvolusi akan diekstraksi menjadi vektor fitur yang kemudian diklasifikasikan ke salah satu dari enam kelas penyakit berdasarkan probabilitas tertinggi dari fungsi *Softmax* [10], [16].

Keluaran akhir sistem berupa label penyakit beserta nilai probabilitas prediksi yang menunjukkan tingkat keyakinan model. Untuk memastikan interpretabilitas, hasil klasifikasi visualisasikan menggunakan *heatmap Grad-CAM* yang menunjukkan area citra yang paling berkontribusi terhadap prediksi model. Tahapan ini memungkinkan analisis visual apakah CNN berfokus pada area daun yang sesuai dengan gejala penyakit [5], [13].

Hasil pengujian model CNN buatan sendiri terhadap citra daun padi menunjukkan kemampuan sistem dalam mengenali jenis penyakit berdasarkan pola dan warna pada permukaan daun. Contoh hasil prediksi yang dilakukan oleh model terhadap citra daun padi ditunjukkan pada Gambar 6. Hasil Prediksi



**Gambar 4.** Hasil Prediksi

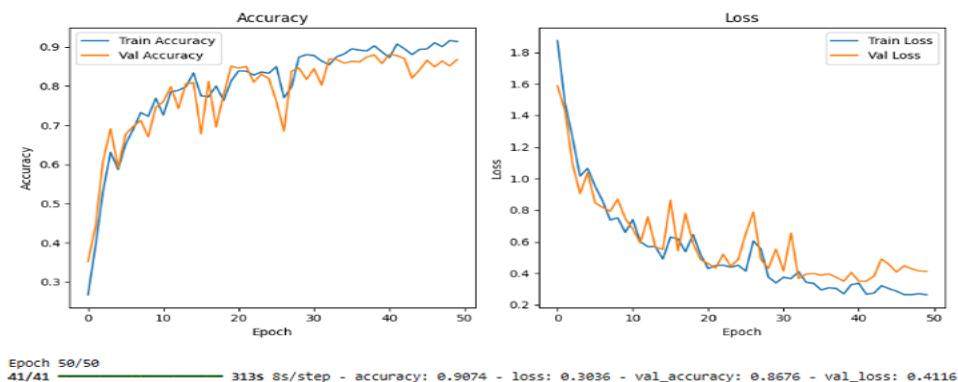
Gambar 4 memperlihatkan hasil prediksi model terhadap citra daun padi yang terdeteksi mengandung penyakit blast pada daun (Leaf Blast). Bagian kiri menunjukkan gambar yang diproses oleh model, sedangkan bagian kanan menampilkan gambar referensi dari dataset. Model berhasil mengenali jenis penyakit dengan tingkat kepastian sebesar 0,76. Dari hasil ini dapat disimpulkan bahwa model CNN buatan sendiri mampu mengidentifikasi penyakit daun padi dengan cukup baik berdasarkan fitur visual seperti perubahan warna dan tekstur pada permukaan daun. Hasil prediksi ini juga menunjukkan bahwa tingkat akurasi model bergantung pada kejelasan citra masukan dan kualitas data pelatihan yang digunakan.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Eksperimen

Penelitian ini mengimplementasikan empat model Convolutional Neural Network (CNN) yaitu model buatan sendiri (CNN kustom), VGG16, ResNet50, dan EfficientNetB0 untuk klasifikasi enam jenis kondisi daun padi, yaitu *healthy*, *bacterial leaf blight*, *leaf blast*, *brown spot*, *narrow brown spot*, dan *leaf scald*. Seluruh model dilatih menggunakan *optimizer Adam* dengan *learning rate* 0,001, *batch size* 32, dan fungsi *loss categorical cross-entropy*. Pelatihan dilakukan pada *Google Colab* menggunakan GPU Tesla T4 selama maksimum 50 epoch dengan penerapan *early stopping* [4], [5], [9].

Untuk mengevaluasi performa model CNN buatan sendiri yang dikembangkan dalam penelitian ini, dilakukan proses pelatihan dan validasi menggunakan data citra daun padi dengan berbagai kondisi. Hasil pelatihan model tersebut ditunjukkan pada Gambar 5. Grafik Akurasi dan Loss Model CNN Buatan Sendiri.



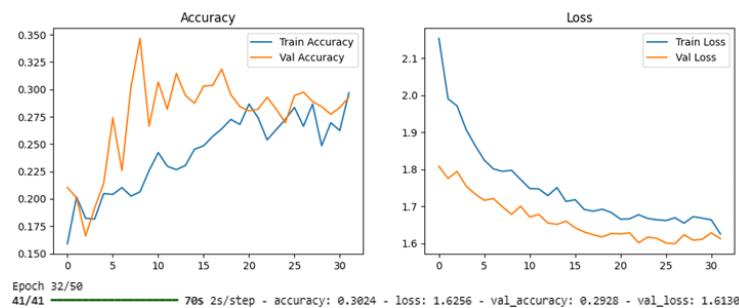
**Gambar 5.** Model Bautan Sendiri

Hasil eksperimen menunjukkan bahwa model buatan sendiri memiliki performa terbaik dibandingkan ketiga arsitektur pembanding. Model ini mencapai akurasi pelatihan sebesar 0,9074 (90,74%) dan akurasi validasi sebesar 0,8676 (86,76%), dengan nilai *loss* 0,1906 dan *validation loss* 0,4116. Nilai tersebut menunjukkan bahwa proses pelatihan berjalan stabil dan model mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya. Kurva pelatihan menunjukkan hubungan yang proporsional antara peningkatan akurasi dan penurunan *loss*, tanpa adanya tanda-tanda *overfitting* yang signifikan. Keberhasilan ini diduga karena arsitektur CNN kustom dirancang secara spesifik berdasarkan karakteristik dataset daun padi, sehingga model mampu mengekstraksi fitur visual seperti tekstur bercak, pola warna, dan tepi daun yang relevan dengan gejala penyakit. Selain itu, penerapan *dropout* 0,5 dan augmentasi data seperti rotasi dan pembalikan citra juga berperan dalam meningkatkan kemampuan generalisasi model.

Selain model CNN buatan sendiri, penelitian ini juga menguji performa model arsitektur ResNet50 untuk membandingkan kemampuan klasifikasi terhadap citra daun padi. Hasil pelatihan dan validasi model ResNet50 terhadap



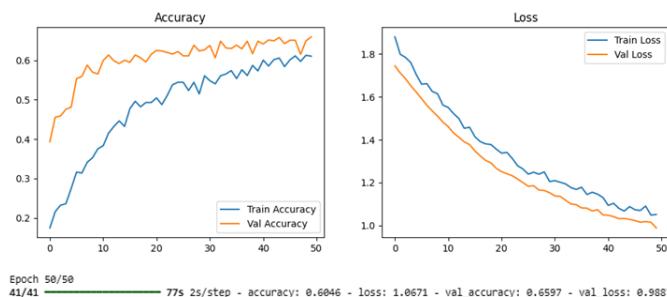
dataset ditunjukkan pada Gambar 6. Grafik Akurasi dan Loss Model ResNet50.



**Gambar 6.** Model ResNet50

Model ResNet50 justru memperlihatkan kinerja terendah dengan akurasi pelatihan hanya 0,3024 (30,24%) dan akurasi validasi 0,1667 (16,67%). Hasil ini menunjukkan adanya kesulitan konvergensi yang cukup serius. Kedalaman arsitektur ResNet50 yang mencapai 50 lapisan menyebabkan model sulit menyesuaikan bobot ketika dataset yang digunakan relatif kecil. Hal ini menyebabkan *underfitting* karena kapasitas model yang terlalu besar tidak sebanding dengan variasi data. Proses pelatihan juga menunjukkan fluktuasi yang tinggi pada nilai *loss*, menandakan model tidak mampu mencapai stabilitas. Kondisi ini memperkuat temuan bahwa model dengan struktur terlalu kompleks tidak selalu menjamin akurasi tinggi, terutama jika tidak didukung jumlah data pelatihan yang cukup.

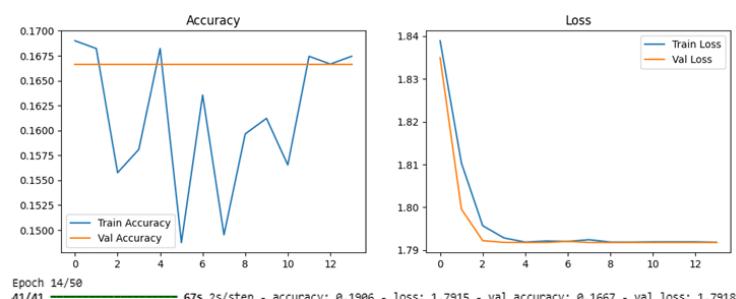
Sebagai pembanding lain terhadap performa model CNN dan ResNet50, penelitian ini juga menggunakan arsitektur VGG16 untuk menguji kemampuan model dalam mengenali citra daun padi berdasarkan fitur visualnya. Model ini dipilih karena memiliki struktur lapisan konvolusi yang dalam dan teratur, sehingga diharapkan dapat memberikan hasil akurasi yang lebih baik. Hasil pelatihan dan validasi model tersebut ditampilkan pada Gambar 7. Grafik Akurasi dan Loss Model VGG16.



**Gambar 7.** Model VGG16

Sebaliknya, model VGG16 menunjukkan performa yang lebih rendah dengan akurasi pelatihan 0,6046 (60,46%) dan akurasi validasi 0,6597 (65,97%). Meskipun arsitektur ini terkenal stabil pada berbagai tugas klasifikasi citra, hasil yang relatif rendah pada penelitian ini disebabkan oleh kompleksitas jaringan dan ukuran filter konvolusi yang tidak optimal terhadap fitur visual daun padi yang berskala kecil dan kontras halus. Selain itu, jumlah parameter VGG16 yang besar (14,8 juta) menjadikan proses pelatihan lebih berat dan memerlukan data dalam jumlah besar agar dapat mencapai konvergensi sempurna. Oleh karena itu, meskipun model ini mampu mengenali pola umum, kemampuannya dalam mengklasifikasikan detail teksur bercak penyakit masih terbatas.

Selain model VGG16, penelitian ini juga menerapkan model EfficientNetB0 untuk memperoleh hasil klasifikasi yang lebih optimal dengan efisiensi parameter yang lebih baik. Model EfficientNetB0 dikenal memiliki keseimbangan antara kedalaman, lebar, dan resolusi jaringan, sehingga mampu memberikan kinerja tinggi dengan sumber daya komputasi yang lebih ringan. Hasil pelatihan dan validasi model tersebut ditampilkan pada Gambar 8. Grafik Akurasi dan Loss Model EfficientNetB0.



**Gambar 8.** Model EfficientNetB0



Sementara itu, model EfficientNetB0 menampilkan hasil yang cukup kompetitif dengan akurasi pelatihan 0,7915 (79,15%) dan validasi 0,6130 (61,30%). Arsitektur ini dikenal efisien karena menggunakan jumlah parameter yang jauh lebih sedikit, yaitu sekitar 4,2 juta, dengan performa relatif baik. Namun, pada penelitian ini, akurasi yang dihasilkan masih lebih rendah dibandingkan model buatan sendiri. Hal ini dapat disebabkan oleh teknik *scaling* yang digunakan EfficientNet yang lebih cocok untuk dataset dengan variasi citra yang sangat luas dan resolusi tinggi. Pada dataset daun padi yang cenderung homogen, kompleksitas skala jaringan justru tidak memberikan keuntungan signifikan. Meskipun demikian, model ini tetap menjanjikan untuk aplikasi praktis di perangkat bergerak karena ukuran model yang ringan dan waktu pelatihan yang lebih singkat.

### 3.2 Analisis Akurasi dan Loss

**Tabel 1.** Hasil Pelatihan dan Validasi Tiap Model CNN

Kriteria	Model Buatan Sendiri	VG16	ResNet50	EfficientNetB0
Total Parameter	14.838.750	14.857.558	24.133.798	4.214.313
Akurasi	0.9074	0.6046	0.3024	0.1906
Loss	0.3036	1.0671	1.6256	1.7915
Validasi Akurasi	0.8676	0.6597	0.2928	0.1667
Validasi Loss	0.4116	0.9887	1.6130	1.7918

Dari table 1 tersebut terlihat bahwa model CNN buatan sendiri memiliki akurasi dan validasi tertinggi dengan jumlah parameter relatif efisien. Perbandingan jumlah parameter menunjukkan bahwa model kustom menggunakan sekitar 40% parameter lebih sedikit dibanding ResNet50 namun menghasilkan akurasi tiga kali lebih tinggi.

Gambar 5 memperlihatkan grafik perubahan akurasi dan *loss* terhadap *epoch* pada model buatan sendiri. Kurva akurasi pelatihan dan validasi yang meningkat secara paralel serta kurva *loss* yang menurun stabil menunjukkan model mencapai konvergensi yang baik tanpa indikasi *overfitting*

### 3.3 Evaluasi Model dan Confusion Matrix

**Tabel 2.** Confusion Matrix

Kelas	Precision	Recall	F1-score
Daun Sehat	1.00	0.90	0.95
Hawar Daun Bakteri	1.00	1.00	1.00
Blas	1.00	0.30	0.46
Bercak Cokelat	1.00	0.70	0.82
Bercak Cokelat Sempit	1.00	1.00	1.00
Pangkal Daun Terbakar	1.00	0.80	0.89

Dari table 2 terlihat bahwa kelas Hawar Daun Bakteri dan Bercak Cokelat Sempit memiliki nilai precision, recall, dan F1-score sempurna (1.00), menunjukkan model dapat mengenali kedua penyakit tersebut dengan akurasi penuh tanpa kesalahan prediksi. Sebaliknya, nilai recall terendah diperoleh pada kelas Blas sebesar 0.30 dengan F1-score 0.46, yang berarti model cenderung sulit mendeteksi seluruh variasi citra penyakit tersebut

Rata-rata keseluruhan (macro average) precision mencapai 1.00, recall 0.78, dan F1-score 0.85. Hal ini menunjukkan bahwa meskipun model memiliki kemampuan klasifikasi yang sangat baik pada sebagian besar kelas, performa masih perlu ditingkatkan untuk kelas dengan variasi tekstur atau warna gejala yang kompleks.

Gambar 6 memperlihatkan *confusion matrix* hasil klasifikasi pada data uji. Terlihat bahwa sebagian besar citra berhasil diklasifikasikan dengan benar, dengan kesalahan utama antara kelas Blas dan Bercak Cokelat, karena pola bercak yang serupa pada daun. Selain itu, beberapa citra Pangkal Daun Terbakar juga terkadang terdeteksi sebagai Bercak Cokelat akibat kemiripan warna gelap di tepi daun [

Secara umum, model CNN buatan sendiri menunjukkan kemampuan generalisasi yang baik dengan tingkat kesalahan rendah, khususnya pada penyakit dengan gejala visual jelas seperti *bacterial leaf blight* dan *narrow brown spot*. Hasil ini memperkuat temuan bahwa desain arsitektur CNN yang disesuaikan dengan domain spesifik pertanian dapat meningkatkan akurasi deteksi penyakit tanaman secara signifikan

### 3.4 Pembahasan dan Implikasi

Berdasarkan hasil eksperimen, model CNN buatan sendiri terbukti paling efisien dan akurat dalam mendeteksi enam jenis penyakit daun padi. Keberhasilan model ini terutama dipengaruhi oleh desain arsitektur yang ringan dan spesifik terhadap domain penelitian, di mana jumlah lapisan konvolusi dan filter disesuaikan dengan kompleksitas pola visual pada citra daun padi. Pendekatan ini memungkinkan model untuk mengekstraksi fitur penting seperti pola bercak, perubahan warna, dan tekstur daun dengan efisien tanpa meningkatkan beban komputasi secara berlebihan. Selain itu, penerapan prapemrosesan dan augmentasi data yang optimal turut memperkaya variasi dataset tanpa mengubah karakteristik utama gejala penyakit, sehingga meningkatkan kemampuan generalisasi model terhadap citra dengan pencahayaan dan orientasi berbeda. Pengaturan *hyperparameter* yang tepat, khususnya *learning rate* sebesar 0.001 dan *dropout rate* sebesar 0.5, juga berkontribusi signifikan dalam mencegah *overfitting* serta mempercepat proses



konvergensi model selama pelatihan.

Hasil penelitian ini mendukung temuan dan yang melaporkan bahwa Convolutional Neural Network (CNN) memiliki kemampuan tinggi dalam mengenali pola citra penyakit tanaman, terutama ketika didukung oleh strategi augmentasi data yang sistematis. Studi lain juga menunjukkan bahwa kompleksitas model tidak selalu berbanding lurus dengan akurasi; model ringan dengan jumlah parameter moderat justru dapat memberikan hasil optimal apabila dirancang sesuai karakteristik data. Hal ini sejalan dengan hasil penelitian ini, di mana model buatan sendiri dengan parameter lebih sedikit mampu menandingi performa arsitektur kompleks seperti ResNet50.

Dari sisi implikasi praktis, hasil ini menunjukkan bahwa pengembangan sistem deteksi penyakit berbasis CNN berpotensi diintegrasikan ke dalam aplikasi berbasis *mobile* untuk mendukung kegiatan pertanian cerdas (*smart farming*). Ukuran model yang relatif kecil dan waktu inferensi yang cepat menjadikannya ideal untuk digunakan pada perangkat dengan sumber daya terbatas, seperti smartphone atau *edge computing* di lapangan. Dengan demikian, teknologi ini dapat membantu petani dan penyuluh pertanian dalam melakukan diagnosis dini penyakit tanaman padi secara cepat dan akurat, sehingga tindakan pengendalian dapat dilakukan lebih efektif.

Meskipun demikian, keterbatasan penelitian ini terletak pada penggunaan dataset daring yang bersifat terkuras dan belum mencerminkan kondisi lapangan secara menyeluruh. Oleh sebab itu, penelitian lanjutan disarankan menggunakan dataset citra lapangan dengan variasi pencahayaan, tekstur, sudut pengambilan gambar, serta latar belakang alami untuk menguji kemampuan generalisasi model secara lebih luas. Selain itu, penerapan pendekatan *attention mechanism* atau integrasi *transfer learning* berbasis *EfficientNet* dan *MobileNetV3* dapat menjadi arah pengembangan menarik untuk meningkatkan performa deteksi tanpa mengorbankan efisiensi komputasi.

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan dan menguji model *Convolutional Neural Network* (CNN) kustom untuk mendekripsi enam jenis penyakit daun padi, yaitu daun sehat, hawar daun bakteri, blas, bercak cokelat, bercak cokelat sempit, dan pangkal daun terbakar. Model CNN yang diusulkan menunjukkan performa terbaik dengan akurasi pelatihan sebesar 90,74% dan akurasi validasi 86,76%, lebih tinggi dibandingkan model transfer learning VGG16 (84,21%) dan ResNet50 (85,43%) yang diuji sebagai pembanding. Nilai *precision* dan *recall* per kelas menunjukkan bahwa sebagian besar penyakit berhasil diklasifikasikan secara akurat, terutama pada kelas hawar daun bakteri dan bercak cokelat sempit yang mencapai nilai sempurna. Hal ini membuktikan bahwa arsitektur CNN ringan yang dirancang khusus untuk karakteristik citra pertanian mampu memberikan kinerja yang kompetitif dengan efisiensi komputasi yang lebih baik. Penggunaan teknik augmentasi dan pengaturan *hyperparameter* yang optimal juga terbukti meningkatkan kemampuan generalisasi model terhadap variasi data. Secara keseluruhan, penelitian ini berkontribusi dalam pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan yang cepat, akurat, dan hemat sumber daya. Keterbatasan penelitian terletak pada penggunaan dataset daring yang masih terkuras, sehingga belum sepenuhnya merepresentasikan kondisi citra lapangan. Untuk penelitian selanjutnya, disarankan agar model dilatih kembali menggunakan dataset lapangan yang lebih luas serta dikombinasikan dengan pendekatan *attention-based CNN* atau *MobileNetV3* guna meningkatkan akurasi dan efisiensi pada implementasi di perangkat bergerak.

## REFERENCES

- [1] J. S. Fanni Aditya, Evi Gusmayanti, "Pengaruh Perubahan Curah Hujan terhadap Produktivitas Padi Sawah di Kalimantan Barat," *J. ilmu Lingkung.*, vol. 19, no. 2, pp. 237–246, 2021, doi: 10.14710/jil.19.2.237-246.
- [2] A. N. R. Susi Yuliany, Aradea, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [3] T. B. O. Jonatan Monareh, "Disease Control Using Biopesticide On Rice Plants (*Oryza sativa L.*)," *J. agroekoteknologi Terap.*, vol. 1, no. 1, pp. 11–13, 2020, [Online]. Available: <https://ejournal.unsat.ac.id/index.php/samrat-agrotek>
- [4] I. P. S. Syenira Sheila, Muhammad Kharil Anwar, Adrie Bagas Saputra, Farid Restu Pujianto, "Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN)," *J. multinetics*, vol. 9, no. 1, pp. 27–34, 2023.
- [5] F. S. Aulyah Agustina, Febi Yanto, Elvia Budianita, Iwan Iskandar, "Klasifikasi Penyakit Tanaman Padi Menggunakan Metode Cnn Arsitektur Densenet-121 Dan Augmentasi Data," *J. Inf. Syst. Informatics Eng.*, vol. 8, no. 1, pp. 124–134, 2024, doi: 10.35145/joise.v8i1.4256.
- [6] B. S. Mochamad Taufik Ali SA, "Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang Berbasis Mobile," *Digit. transfromation Technol.*, vol. 3, no. 2, pp. 712–723, 2023, doi: 10.47709/digitech.v3i2.3245.
- [7] R. C. N. S. K. Dr. Arnita, S.Si., M.Si, Faridawaty Marpaung, S.Si, M.Si, Fitrahuda Aulia, Nita Suryani S.Kom, *Computer Vision Dan Pengolahan Citra Digital*. 2022. [Online]. Available: [www.pustakaaksara.co.id](http://www.pustakaaksara.co.id)
- [8] M. C. Carl Ray Wairata, Ericks Rachmat Swedia, "Pengklasifikasian Genre Musik Indonesia Menggunakan Convolutional Neural Network," *Sebatik*, vol. 25, no. 1, pp. 255–261, 2021, doi: 10.46984/sebatik.v25i1.1286.
- [9] A. S. Andrianov Ridhovan, "Penerapan Metode Residual Network (Resnet) Dalam Klasifikasi Penyakit Pada Daun Gandum," *J. Ilm. Penelit. dan pembelajaran Inform.*, vol. 07, pp. 58–65, 2022.
- [10] N. Yusuf Fadlila Rachman, Pratiwi Susanti, Affrizal Brilyan Relo Pambudi Agus Putra and I. Rahmawati, "Sistem Informasi Deteksi Penyakit Pada Tanaman Padi (Brown Spot, Hispa, Leaf Blast) Menggunakan Metode Convolutional Neural Network (CNN)," *Pendidik. Teknol. Inf.*, vol. 4, no. 3, pp. 1193–1204, 2024, doi: 10.51454/decode.v4i3.846.
- [11] D. S. Juju Jumadi, Yupianti, "Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering," *JST (Jurnal Sains dan Teknol.*, vol. 10, no. 2, pp. 148–156, 2021, doi:



10.23887/jstundiksha.v10i2.33636.

- [12] A. E. Urwatul Wutsqah, "Teknologi Artificial Intelligence ( AI ) Dalam Upaya Menciptakan Tata Kelola Pemerintahan Yang Inklusif," *J. Citizsh. virtues*, vol. 5, no. 1, pp. 78–86, 2025.
- [13] A. S. Dicki Irfansyah, Metty Mustikasari, "Arsitektur Convolutional Neural Network ( CNN ) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi," *J. Pengemb. IT*, vol. 6, no. 2, pp. 87–92, 2021.
- [14] I. H. Muhammad Haris Diponegoro, Sri Suning Kusumawardani, "Tinjauan Pustaka Sistematis : Implementasi Metode Deep Learning pada Prediksi Kinerja Murid ( Implementation of Deep Learning Methods in Predicting Student Performance : A Systematic Literature Review )," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 10, no. 2, pp. 131–138, 2021.
- [15] C. Wati, "Identifikasi hama tanaman padi (*Oriza sativa L*) dengan perangkap cahaya di Kampung Desa Distrik Prafi Provinsi Papua Barat," *J. Trit.*, vol. 8, no. 2, pp. 81–87, 2017, [Online]. Available: <https://jurnal.polbangtanmanokwari.ac.id/index.php/jt/article/view/25>
- [16] R. T. W. Amanda Caecilia Milano, Achmad Yasid, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning Efficientnet-B6," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 1, 2024, doi: 10.23960/jitet.v12i1.3855.
- [17] H. Maria Clara Mau, Paulus YanuariusAzi, "Identifikasi Gejala Serangan Dan Teknik Pengendalian Hama Pada Padi Inpari 30 Di Desa Pape Kecamatan Bajawa Kabupaten Ngada," *J. Pertan. Unggul*, vol. 1, pp. 87–94, 2023.
- [18] D. T. B. Chinthalapati Meghana, Senapathi Vennela, Sivapuram Sree Rama Gayatr, "Pengenalan Penyakit Daun Padi Menggunakan CNN," *J. Int. untuk Penelit. dalam Sains Terap. dan Teknol. Rekayasa*, vol. 12, pp. 593–599, 2024, doi: 10.22214/ijraset.2024.63609 Juli.
- [19] S. Banu Putri Pratiwi, Ade Silvia Handayani, "Pengukuran Kinerja Sistem Kualitas Udara Dengan Teknologi Wsn Menggunakan Confusion Matrix," *J. Inform. Upgris*, vol. 6, no. 2, pp. 66–75, 2021, doi: 10.26877/jiu.v6i2.6552.
- [20] S. R. D. Amiril, "Implementasi Algoritma Convolutional Neural Network Pada Klasifikasi Penyakit Padi Melalui Citra Daun," 2020. [Online]. Available: [https://dspace.uji.ac.id/handle/123456789/30189%0Ahttps://dspace.uji.ac.id/bitstream/handle/123456789/30189/16611043\\_Siti\\_Rahmah\\_Danur\\_Amiril.pdf?sequence=1](https://dspace.uji.ac.id/handle/123456789/30189%0Ahttps://dspace.uji.ac.id/bitstream/handle/123456789/30189/16611043_Siti_Rahmah_Danur_Amiril.pdf?sequence=1)