

CESS

(Journal of Computer Engineering, System and Science)

Available online: <https://jurnal.unimed.ac.id/2012/index.php/cess>

ISSN: 2502-714x (Print) | ISSN: 2502-7131 (Online)



Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2

Classification Of Rice Leaf Disease Images With CNN Method Using ResNet50V2 Architecture

Muhamad Filla Akbar Maulana^{1*}, Nanda Martyan Anggadimas², Dian Ahkam Sani³

^{1,2,3}Teknik Informatika, Teknologi Informatika, Universitas Merdeka Pasuruan
Jl. Ir. H. Juanda No.68, Tapaan, Kec. Bugul Kidul, Kota Pasuruan

Email: ¹akbarmaulana@student.unmerpas.ac.id, ²dian.ahkam@unmerpas.ac.id,

³nandama@unmerpas.ac.id

*Corresponding Author

ABSTRAK

Tanaman padi sangat penting untuk menjaga ketersediaan pangan di Indonesia. Namun, produksinya sering menurun karena berbagai masalah, salah satunya yaitu penyakit daun yang sulit dikenali sejak awal. Jika penyakit tidak cepat dikenali dan ditangani, hal ini bisa menyebabkan hasil panen menurun drastis dan mengganggu pasokan beras di dalam negeri. Oleh karena itu, penelitian ini bertujuan untuk pengembangan sistem identifikasi penyakit daun padi otomatis. Sistem ini memanfaatkan citra digital dan jaringan saraf tiruan *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50V2 untuk mengenali delapan jenis penyakit: *Bacterial Leaf Blight*, *Brown Spot*, *Leaf Blast*, *Leaf Scald*, *Narrow Brown Spot*, *Rice Hispa*, *Sheath Blight*, dan *Tungro*. Data citra diperoleh dari platform Kaggle, dengan total 15.241 gambar yang telah melalui tahapan *preprocessing* seperti normalisasi piksel, augmentasi, dan perubahan ukuran menjadi 224x224 piksel. Model CNN dilatih menggunakan pendekatan *transfer learning* selama 50 *epoch* dengan bantuan dua fitur *callback* untuk menjaga kualitas pelatihan. Evaluasi performa dilakukan melalui *confusion matrix* dan *classification report*. Berdasarkan hasil pengujian, model menunjukkan akurasi tertinggi sebesar 94,14% pada data uji, serta nilai *precision*, *recall*, dan *f1-score* yang tinggi di hampir seluruh kelas. Dari hasil ini membuktikan bahwa CNN berbasis ResNet50V2 efektif digunakan untuk mendeteksi penyakit daun padi secara otomatis, dan berpotensi diterapkan sebagai alat bantu bagi petani dalam mempercepat proses identifikasi dan pengambilan keputusan di bidang pertanian.

Kata Kunci: *Klasifikasi; Penyakit Daun Padi; Convolutional Neural Network; ResNet50V2*



ABSTRACT

Rice crops are crucial for maintaining food security in Indonesia. However, production often declines due to various issues, one of which is leaf diseases that are difficult to identify early. If the disease is not quickly identified and treated, it can lead to a drastic decline in yields and disrupt domestic rice supply. Therefore, this study aims to develop an automatic rice leaf disease identification system. This system utilizes digital images and a Convolutional Neural Network (CNN) with the ResNet50V2 architecture to recognize eight types of diseases: Bacterial Leaf Blight, Brown Spot, Leaf Blast, Leaf Scald, Narrow Brown Spot, Rice Hispa, Sheath Blight, and Tungro. Image data was obtained from the Kaggle platform, with a total of 15,241 images that have undergone preprocessing stages such as pixel normalization, augmentation, and resizing to 224x224 pixels. The CNN model was trained using a transfer learning approach for 50 epochs with the help of two callback features to maintain training quality. Performance evaluation was carried out through a confusion matrix and a classification report. Based on the test results, the model demonstrated the highest accuracy of 94.14% on the test data, as well as high precision, recall, and f1-score values across almost all classes. These results demonstrate that the ResNet50V2-based CNN is effective for automatically detecting rice leaf diseases and has the potential to be implemented as a tool for farmers to accelerate the identification process and decision-making in the agricultural sector.

Keywords: *Classification; Rice Leaf Disease; Convolutional Neural Network; ResNet50V2*

1. PENDAHULUAN

Padi (*Oryza sativa L.*) adalah tanaman semusim dari golongan rumput-rumputan yang berumur pendek, kurang dari setahun. Sebagai komoditas pangan utama, padi menjadi makanan pokok bagi hampir 90% penduduk Indonesia [1]. Perekonomian Indonesia sangat bergantung pada sektor pertanian, khususnya produksi padi, karena padi adalah sumber pangan utama bagi penduduknya. Beras, yang berasal dari padi, memegang peran strategis dalam memenuhi kebutuhan makanan masyarakat akibat tingginya tingkat konsumsi. Mayoritas penduduk Indonesia mengandalkan beras sebagai bahan makanan pokok. Namun, produksi padi sering terhambat oleh berbagai tantangan, seperti berkurangnya lahan pertanian akibat alih fungsi, perubahan cuaca ekstrem, serta serangan hama dan penyakit yang merusak tanaman. Faktor-faktor ini semakin mengancam hasil panen, sehingga berdampak pada ketersediaan beras di dalam negeri. Penurunan produksi padi tidak hanya disebabkan oleh perubahan kondisi lingkungan, tetapi juga oleh meningkatnya intensitas serangan hama dan penyakit yang merusak tanaman [2].

Convolutional Neural Network (CNN) umum digunakan dalam pengolahan citra karena akurasi tinggi dan kemampuannya yang unggul dalam mengenali gambar visual [3]. CNN memiliki kemampuan mengenali pola visual yang kompleks, sehingga cocok untuk menganalisis citra daun padi yang terkena penyakit. Dalam konteks pertanian, penerapan CNN untuk mendeteksi penyakit daun padi menjadi solusi yang tepat untuk meningkatkan efisiensi dan akurasi diagnosis penyakit. Dengan menggunakan dataset citra daun padi, CNN mampu mempelajari dan mengenali citra daun padi yang terbagi menjadi tiga kategori penyakit:

hawar daun bakteri (*bacterial leaf blight*), gosong daun (*leaf smut*), dan bercak coklat (*brown spot*) [4].

Pemanfaatan metode CNN perlu dibandingkan dengan algoritma lain untuk memastikan keunggulannya. Pada penelitian sebelumnya telah membandingkan CNN dengan algoritma *Multi-Layer Perceptron* (MLP), sebuah pendekatan pembelajaran mesin tradisional. Dalam penelitian tersebut, CNN menunjukkan hasil yang jauh lebih baik dengan tingkat akurasi mencapai 98%, sementara MLP hanya mampu meraih 43%. CNN tidak hanya unggul dalam akurasi, tetapi juga menunjukkan performa superior pada metrik evaluasi lain seperti presisi, *recall*, dan *F1-score*. Ini membuktikan bahwa CNN lebih efektif dalam mengenali pola kompleks pada citra dibandingkan MLP, meskipun proses pelatihannya memakan waktu lebih lama. Dengan demikian, CNN adalah pilihan terbaik untuk aplikasi klasifikasi citra dalam deteksi penyakit daun padi [5].

Untuk mendukung argumen penggunaan *Convolutional Neural Network* (CNN) dalam penelitian ini, kami merujuk pada berbagai literatur yang telah membuktikan keberhasilan metode ini pada berbagai jenis objek tanaman. CNN terbukti memiliki potensi besar dalam mengklasifikasikan penyakit tanaman berbasis citra daun secara akurat. Pada tanaman tomat, pendekatan transfer *learning* dengan arsitektur Inception V3 berhasil mencapai akurasi hingga 93,8% menggunakan optimizer Adam [6]. Penelitian serupa pada tanaman kentang menunjukkan bahwa model CNN dengan tiga kelas klasifikasi daun sehat, early blight, dan late blight mampu menghasilkan akurasi pelatihan 95% dan akurasi validasi 94% hanya dalam 10 epoch [7]. Sementara itu, pada tanaman jeruk siam, penggunaan CNN dengan arsitektur EfficientNetB3 untuk klasifikasi enam jenis penyakit daun berhasil mencapai akurasi terbaik sebesar 98%, menandakan keandalan model ini dalam mendeteksi penyakit secara cepat [8]. Pada kasus tanaman jagung, model CNN juga menunjukkan performa optimal dengan akurasi pelatihan 91,5% dan validasi 91%, memperlihatkan kemampuannya dalam mengenali masalah kesehatan tanaman secara efisien [9]. Selain itu, dalam klasifikasi penyakit daun tembakau, metode CNN berbasis transfer *learning* menggunakan arsitektur MobileNet menghasilkan nilai *precision* 73%, *recall* 69%, *F1-score* 68%, dan akurasi data uji sebesar 69% [10]. Secara keseluruhan, temuan-temuan tersebut mempertegas bahwa CNN merupakan metode yang efektif untuk diterapkan dalam sistem deteksi penyakit tanaman, termasuk dalam penelitian ini yang berfokus pada identifikasi penyakit daun berbasis citra digital.

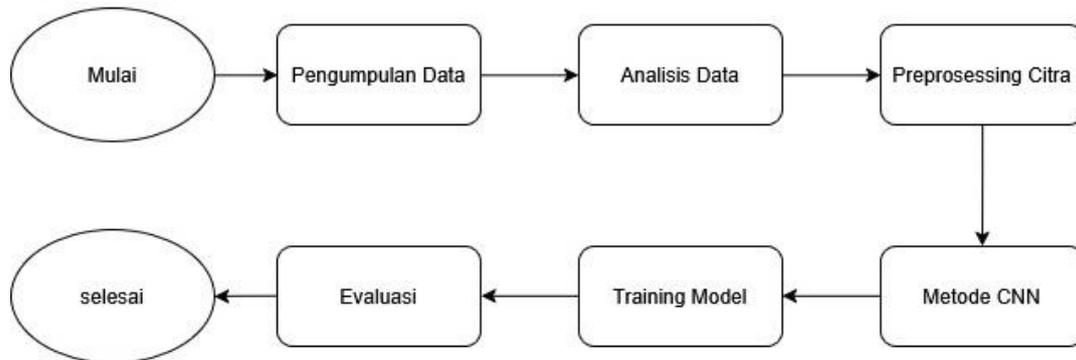
Efektivitas CNN dalam mendeteksi penyakit tanaman telah dibuktikan melalui berbagai studi internasional. Oleh karena itu, Penelitian yang berjudul *Review on Convolutional Neural Network Applied to Plant Leaf Disease Classification* menjelaskan bahwa CNN mampu mengenali pola visual pada daun tanaman secara akurat, sehingga dapat digunakan dalam proses klasifikasi penyakit [11]. Penelitian lainnya, *Improved EfficientNet for Corn Disease Identification*, menunjukkan bahwa model EfficientNet yang telah dimodifikasi mampu mendeteksi penyakit daun jagung dengan akurasi tinggi dan stabil di berbagai kondisi [12]. Sementara itu, studi berjudul *Comparing Pre-Trained Models for Efficient Leaf Disease Detection: A Study on Custom CNN* membandingkan beberapa model CNN pra-latih dengan model buatan sendiri, dan Hasilnya menunjukkan bahwa model buatan mereka mampu bekerja secara efektif namun tetap akurat dalam mendeteksi penyakit tanaman [13].

Penelitian ini berupaya menggunakan CNN untuk mendeteksi penyakit pada daun padi. Harapannya, dengan metode ini, petani bisa lebih mudah mengidentifikasi penyakit yang menyerang tanaman mereka melalui teknologi citra digital. Hal ini tidak hanya membantu meningkatkan efisiensi waktu dalam diagnosis, tetapi juga mendorong penerapan langkah-

langkah pengendalian yang lebih cepat dan akurat. Akhirnya, penelitian ini diharapkan mampu memberikan kontribusi pada pengembangan teknologi pertanian yang lebih maju, mendukung keberlanjutan sektor agraris, dan meningkatkan ketahanan pangan nasional.

2. METODE PENELITIAN

Metode CNN digunakan untuk mengenali pola pada citra daun padi, seperti tekstur dan bercak. Model ini menggunakan arsitektur ResNet50V2 untuk membantu proses pelatihan. CNN dilatih agar bisa membedakan delapan jenis penyakit daun padi dengan akurasi yang diukur pada tahap evaluasi.



Gambar 1. Perancangan Sistem

2.1 Pengumpulan Data

Penelitian ini menggunakan dataset citra daun padi yang diambil dari platform Kaggle yang diunggah oleh akun bernama pawweekorns, Berisi gambar yang telah diklasifikasikan ke dalam delapan jenis penyakit, yaitu Bacterial Leaf Blight, Brown Spot, Leaf Blast, Leaf Scald, Narrow Brown Spot, Rice Hispa, Sheath Blight, dan Tungro [14]. Tiap kelas menunjukkan pola visual yang berbeda satu sama lain.



Gambar 2. Bacterial Leaf Blight



Gambar 3. Tungro



Gambar 4. Sheath Blight



Gambar 5. Narrow Brown Spot



Gambar 6. Leaf Blast



Gambar 7. Brown Spot



Gambar 8. Leaf Scald



Gambar 9. Rice Hispa

2.3 Analisis Data

Analisis data dilakukan untuk meninjau kualitas, keseimbangan, dan keberagaman citra daun padi yang digunakan dalam penelitian ini. Dataset yang dianalisis berisi total 15.241 gambar, terdiri dari 12.532 gambar data latih (*train*) dan 2.709 gambar data uji (*test*), yang diklasifikasikan ke dalam 8 kategori penyakit daun padi.

2.3.1 Keseimbangan Data Gambar

Seluruh dataset dibagi menjadi dua bagian, yaitu data latih (*train*) dan data uji (*test*). Rincian jumlah gambar per kategori dapat dilihat sebagai berikut:

Tabel 1. Total Gambar Train dan Test

| No. | Kategori Penyakit Daun Padi | Train | Test | Total |
|-------|-----------------------------|--------|-------|--------|
| 1. | Bacterial Leaf Blight | 1.386 | 376 | 1.762 |
| 2. | Brown Spot | 1.480 | 380 | 1.860 |
| 3. | Leaf Blast | 1.801 | 362 | 2.163 |
| 4. | Leaf Scald | 1.670 | 386 | 2.056 |
| 5. | Narrow Brown Spot | 1.416 | 382 | 1.798 |
| 6. | Rice Hispa | 1.461 | 225 | 1.686 |
| 7. | Sheath Blight | 1.578 | 288 | 1.866 |
| 8. | Tungro | 1.740 | 310 | 2.050 |
| Total | | 12.532 | 2.709 | 15.241 |

2.3.2 Gejala Penyakit Daun Padi

Berikut merupakan gejala penyakit daun padi yang dapat dilihat di Tabel 2.

Tabel 2. Gejala Penyakit Daun Padi

| No. | Jenis Penyakit | Penyebab | Gejala |
|-----|-----------------------|----------------------------|--|
| 1. | Bacterial Leaf Blight | <i>Xanthomonas oryzae</i> | Bercak coklat kekuningan memanjang di tepi daun, daun menggulung dan mengering. |
| 2. | Brown Spot | <i>Bipolaris oryzae</i> | Bercak bulat hingga oval, coklat gelap di tengah dan kuning di tepinya. |
| 3. | Leaf Blast | <i>Pyricularia oryzae</i> | Bercak belah ketupat dengan bagian tengah abu-abu dan pinggiran coklat. |
| 4. | Leaf Scald | <i>Microdochium oryzae</i> | Luka basah di ujung daun yang membentuk pola terbakar dan menyebabkan daun kering. |
| 5. | Narrow Brown Spot | <i>Cercospora oryzae</i> | Bercak sempit memanjang sejajar tulang daun, berwarna coklat tua. |

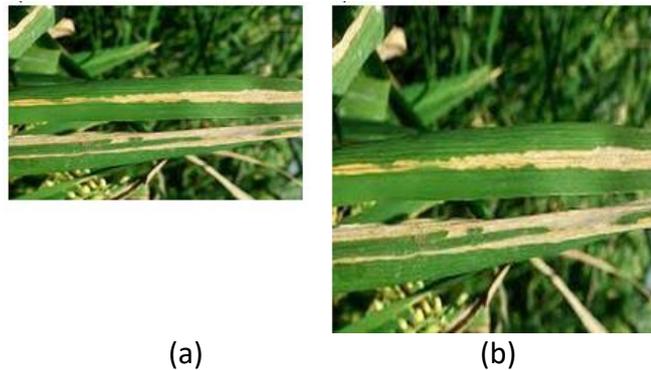
| | | | |
|----|---------------|--------------------------------------|---|
| 6. | Rice Hispa | Serangga <i>Di cladispa armigera</i> | Garis putih sejajar di daun, jaringan daun rusak akibat kikisan dan terowongan larva. |
| 7. | Sheath Blight | <i>Rhizoctonia solani</i> | Bercak hijau abu-abu pada pelepah dan daun bawah, menyebar ke atas. |
| 8. | Tungro | Virus melalui wereng hijau | Daun menguning, menggulung, tanaman kerdil, malai tidak berkembang sempurna. |

2.3.3 Kelengkapan Data

Setelah dilakukan pengecekan, tidak ditemukan adanya *missing* data dalam dataset. Semua gambar bisa diakses dengan baik, memiliki label yang sesuai, dan tidak ada file yang rusak atau gagal dibuka dan tersusun dalam folder berdasarkan masing-masing kategori penyakit.

2.3.4 Format dan Resolusi Gambar

Semua gambar dalam dataset menggunakan format .JPG dan sudah melalui proses *resize* ke ukuran 224x224 piksel, menyesuaikan dengan standar input yang dibutuhkan oleh model ResNet50V2. Berikut *Resize* ditunjukkan gambar 10.



Gambar 10. (a) Gambar Sebelum di-*resize*, (b) Gambar Sesudah di-*resize*

2.4 Preprocessing Citra

2.4.1 Normalisasi Piksel

Tahap ini bertujuan untuk menyesuaikan nilai warna pada gambar dengan cara mengubah rentang piksel dari 0–255 menjadi 0–1. Fungsi *rescale* yang membagi setiap nilai piksel dengan 255. Dengan normalisasi, data gambar menjadi lebih ringan dan mudah diproses oleh model. Pada gambar daun padi, normalisasi membantu model mengenali gejala penyakit dengan lebih cepat, akurat, dan stabil.

2.4.2 Augmentasi Gambar

Augmentasi adalah cara untuk menambah jumlah data pelatihan dengan memodifikasi gambar asli, tapi tanpa mengubah jenis atau label gambarnya. Beberapa variasi augmentasi yang digunakan rotasi, perubahan posisi, menggeser, zoom, membalik, dan mode isi. Tujuannya supaya model tidak hanya hafal gambar yang itu-itu saja, tapi bisa mengenali pola dari berbagai variasi gambar yang berbeda. Berikut hasil dari augmentasi yang ditunjukkan Gambar 11.



Gambar 11. Hasil Aaugmentasi

2.4.3 Pemisahan Dataset

Dataset gambar daun padi dibagi menjadi dua bagian: 80% untuk melatih model dan 20% untuk validasi. Tujuannya agar model belajar dengan baik, tidak *overfitting*, dan mampu mengenali penyakit dengan lebih akurat. Berikut pemisahannya dapat dilihat pada Tabel 3.

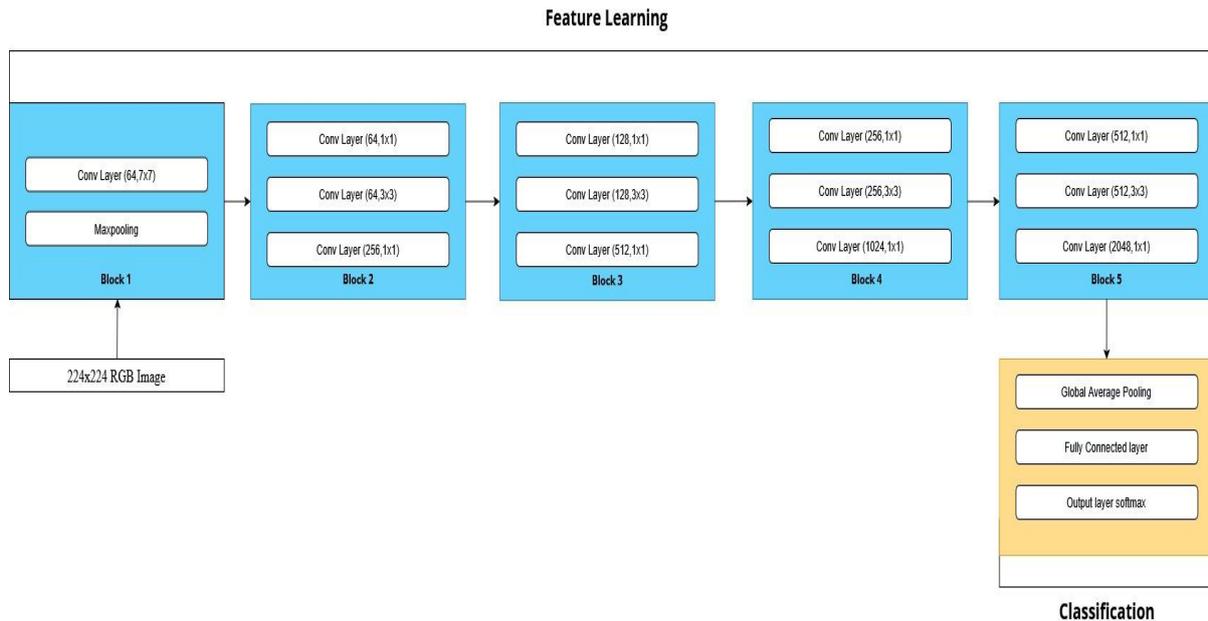
Tabel 3. Detail Pemisahan Dataset

| No. | Kategori Penyakit | Train (80%) | Validasi (20%) | Total |
|-------|-----------------------|-------------|----------------|--------|
| 1. | Bacterial Leaf Blight | 1.108 | 278 | 1.386 |
| 2. | Brown Spot | 1.184 | 296 | 1.480 |
| 3. | Leaf Blast | 1.441 | 360 | 1.801 |
| 4. | Leaf Scald | 1.336 | 334 | 1.670 |
| 5. | Narrow Brown Spot | 1.133 | 283 | 1.416 |
| 6. | Rice Hispa | 1.169 | 292 | 1.461 |
| 7. | Sheath Blight | 1.262 | 316 | 1.578 |
| 8. | Tungro | 1.392 | 348 | 1.740 |
| Total | | 10.025 | 2.507 | 12.532 |

Data *test* tetap digunakan sebanyak 2.709 gambar dan tidak dibagi ulang. Hal ini bertujuan agar evaluasi model menggunakan data yang benar-benar baru dan belum pernah digunakan saat pelatihan.

2.5 Perancangan Model CNN

Algoritma atau metode dalam penelitian ini menggunakan arsitektur ResNet50V2. Proses ResNet50V2 sendiri terdiri dari dua tahap utama, yaitu tahap ekstraksi fitur (*feature learning*) dan tahap klasifikasi (*classification*). Desain arsitektur ResNet50V2 yang digunakan dalam penelitian ini dapat digambarkan sebagai berikut:



Gambar 12. Arsitektur ResNet50V2

Pada tahap *feature learning*, model mulai mengenali pola-pola dari gambar daun padi, seperti bentuk, warna, dan teksturnya. Proses ini berlangsung melalui beberapa lapisan, seperti convolutional layer yang berfungsi menangkap pola penting, batch normalization untuk menjaga kestabilan proses belajar, ReLU untuk membantu model belajar, dan pooling mengecilkan ukuran gambar. Gambar berukuran 224x224 piksel akan melewati tahapan ini.

Selanjutnya, model memasuki tahap klasifikasi. Pada bagian ini, seluruh informasi yang sudah dipelajari diringkas melalui *Global Average Pooling*, lalu dilanjutkan ke lapisan *fully connected* untuk mengolah hasilnya. Di akhir proses, model menggunakan fungsi *softmax* untuk memilih salah satu dari delapan jenis penyakit berdasarkan nilai probabilitas tertinggi.

2.6 Training model

Mempersiapkan model ResNet50V2 sebelum pelatihan, menyetelnya dengan optimizer Adam (tingkat pembelajaran 0.0001) dan fungsi *loss categorical_crossentropy*. Pemilihan fungsi loss ini penting mengingat ada delapan kelas yang akan diklasifikasikan oleh model.

Sebelum dilatih, model ResNet50V2 dikonfigurasi menggunakan optimizer Adam dengan *learning rate* 0.0001 dan fungsi *loss categorical_crossentropy*, karena klasifikasi yang dilakukan terdiri dari 8 kelas. Evaluasi model menggunakan metrik akurasi. Pelatihan dilakukan hingga maksimal 50 epoch dengan data latih dan data validasi. Untuk menjaga kualitas pelatihan, digunakan dua fitur tambahan (*callback*), yaitu *Early Stopping* untuk menghentikan pelatihan jika tidak ada peningkatan dalam 5 epoch, dan *Model Checkpoint* untuk menyimpan model terbaik secara otomatis. Setelah proses selesai, model terbaik dimuat kembali menggunakan fungsi `load_model("best_resnet_model.keras")` dan digunakan untuk pengujian.

2.7 Evaluasi

Dari *confusion matrix*, beberapa metrik evaluasi penting dapat dihitung, seperti akurasi, presisi, recall, dan F1-Score. Akurasi digunakan untuk mengukur proporsi prediksi yang benar

terhadap seluruh data yang diuji. Metrik ini memberikan gambaran umum mengenai seberapa baik model dalam melakukan prediksi. Rumus yang digunakan adalah sebagai berikut:

1. Akurasi (*Accuracy*)

Akurasi menunjukkan seberapa banyak prediksi yang benar dibandingkan dengan seluruh data yang diuji[15].

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

2. Presisi (*Precision*)

Presisi menunjukkan seberapa tepat model dalam memprediksi data ke dalam satu kelas tertentu [15].

$$Presisi = \frac{TP}{TP+FP} \quad (2)$$

3. Recall (*Sensitivity*)

Recall menilai seberapa efektif model dalam mengenali seluruh data yang memang benar-benar berasal dari kelas tertentu [15].

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

4. F1-Score

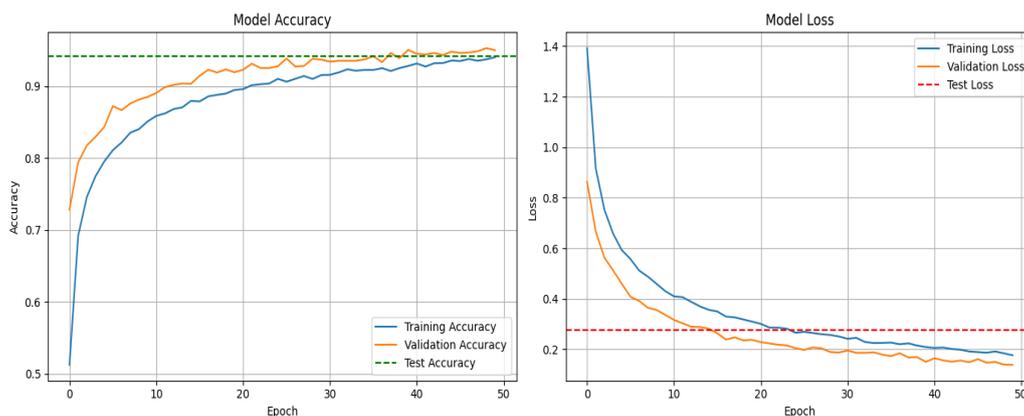
F1-Score merupakan rata-rata harmonis antara presisi dan recall, yang berguna ketika diperlukan keseimbangan antara keduanya, terutama pada data yang tidak seimbang [15].

$$F1 - Score = 2x \frac{Presisi \times Recall}{Presisi+Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1. Implementasi

Hasil pengujian dari implementasi tahapan perancangan sistem pada proses pelatihan menunjukkan bahwa pada epoch terakhir yaitu epoch ke-50, Pada data training mencapai akurasi sebesar 94,08% dengan *loss* 0,1729 dan pada data validasi 95,01% dengan *loss* 0,1388. Nilai akurasi ini menggambarkan kinerja model selama proses pelatihan, yang ditampilkan pada grafik akurasi dan *loss* di Gambar 13.



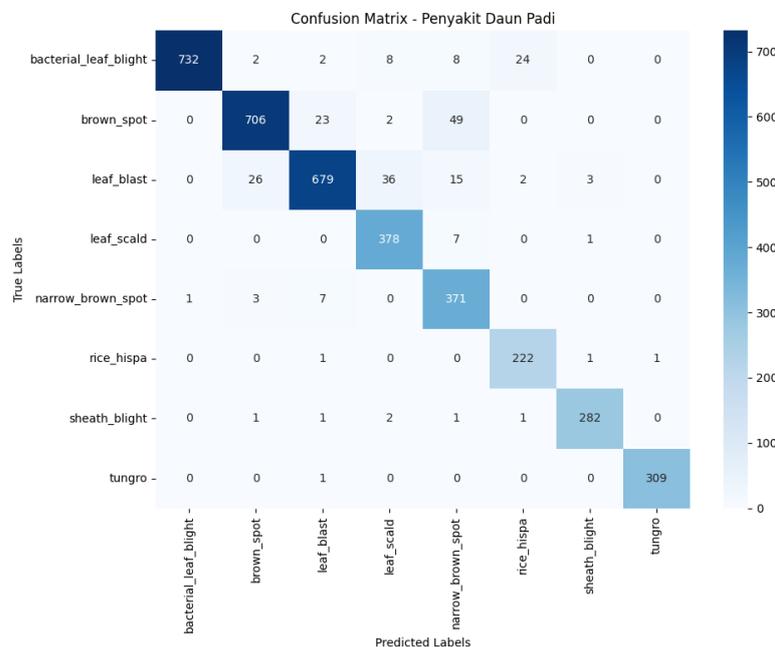
Gambar 13. Grafik Akurasi dan Loss

Pada grafik akurasi (*Accuracy*), terlihat bahwa peningkatan awal dari epoch ke-0 hingga epoch ke-10. Setelah itu pada epoch ke-30, akurasi terus meningkat secara perlahan dan stabil dengan nilai di atas 90% pada data pelatihan maupun validasi. Perbedaan antara keduanya sangat kecil, menandakan bahwa model mampu melakukan generalisasi dengan baik dan tidak mengalami *overfitting*. Garis hijau putus-putus menunjukkan akurasi pada data uji (test accuracy), yang berada di 94,14% , menandakan bahwa model memiliki kemampuan generalisasi yang baik karena performa pada data uji sebanding dengan data validasi.

Pada grafik *loss* (Loss), nilai *loss* mengalami penurunan tajam dari epoch 0 hingga sekitar epoch 10. Setelah itu, nilai *loss* terus menurun namun dengan laju yang lambat dan akhirnya stabil pada nilai rendah. Garis merah putus-putus menunjukkan nilai *loss* pada data uji (test loss) di angka 0,26 mengindikasikan bahwa model tidak mengalami *overfitting*.

3.2 Confusion Matrix

Selain melihat akurasi secara keseluruhan, evaluasi performa model juga dilakukan menggunakan *confusion matrix*. *Confusion matrix* memberikan gambaran detail mengenai sejauh mana model mampu mengklasifikasikan masing-masing kelas dengan benar serta mendeteksi kesalahan klasifikasi yang terjadi. Berikut visualisasi *confusion matrix* ditunjukkan pada Gambar 14.



Gambar 14. Confusion Matrix Penyakit Daun Padi

Pada *confusion matrix* di Gambar 14, setiap angka menunjukkan jumlah prediksi model terhadap masing-masing kelas penyakit daun padi. Pada kelas *bacterial leaf blight*, model berhasil memprediksi 732 data dengan benar dan melakukan kesalahan pada 44 data lainnya. Sementara itu, pada kelas *brown spot*, model memprediksi dengan benar sebanyak 706 data dan gagal pada 74 data. Untuk kelas *leaf blast*, prediksi benar berjumlah 679 data, dan sisanya salah prediksi ke beberapa kelas lain sebanyak 82 data.

Begitu juga pada kelas *leaf scald*, model berhasil memprediksi 378 data dengan benar dan salah pada 8 data. Kelas *narrow brown spot* memiliki 371 prediksi benar dan 11 salah. Sedangkan pada kelas *rice hispa*, terdapat 222 prediksi benar dan 3 data yang salah. Kelas

sheath blight diprediksi dengan benar sebanyak 282 data dan salah 6 data. Terakhir, kelas tungro memiliki 309 data yang diprediksi dengan tepat dan hanya 1 data yang salah. Untuk detail lebih lanjut mengenai performa confusion matrix dapat dilihat pada tabel 4.

Tabel 4. Hasil Confusion Matrix

| Kelas | <i>Precision</i> | <i>Recall</i> | <i>F1-Score</i> | <i>Support</i> |
|-----------------------|------------------|---------------|-----------------|----------------|
| Bacterial Leaf Blight | 1.00 | 0.94 | 0.97 | 776 |
| Brown Spot | 0.96 | 0.91 | 0.93 | 780 |
| Leaf Blast | 0.95 | 0.89 | 0.92 | 761 |
| Leaf Scald | 0.89 | 0.98 | 0.93 | 386 |
| Narrow Brown Spot | 0.82 | 0.97 | 0.89 | 382 |
| Rice Hispa | 0.94 | 0.98 | 0.94 | 225 |
| Sheath Blight | 0.98 | 0.98 | 0.98 | 288 |
| Tungro | 1.00 | 1.00 | 1.00 | 310 |
| Accuracy | | | 0.94 | 3908 |

Hasil evaluasi pada tabel 4 menunjukkan bahwa model memiliki kinerja yang sangat baik dalam mengklasifikasikan delapan jenis penyakit daun padi, dengan akurasi keseluruhan mencapai 94% dari total 3.908 data uji. Beberapa kelas menunjukkan performa yang sangat tinggi, seperti *Tungro* yang memperoleh nilai *precision*, *recall*, dan *f1-score* sebesar 1.00, artinya seluruh data berhasil diprediksi dengan benar. Kelas *Sheath Blight* dan *Bacterial Leaf Blight* juga menunjukkan nilai *f1-score* tinggi, yaitu 0.98 dan 0.97. Kelas lain seperti *Leaf Scald*, *Rice Hispa*, dan *Brown Spot* memiliki nilai evaluasi yang cukup baik, dengan *precision* dan *recall* di atas 0.90. Sementara itu, *Leaf Blast* dan *Narrow Brown Spot* memiliki *recall* yang tinggi, namun *precision*-nya sedikit lebih rendah, menunjukkan masih ada kesalahan dalam memprediksi kelas tersebut.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, Penelitian ini berhasil menerapkan metode *Convolutional Neural Network* (CNN) dengan arsitektur *ResNet50V2* untuk mengklasifikasikan delapan jenis penyakit daun padi. Berdasarkan hasil evaluasi, model ini menunjukkan performa tinggi dengan akurasi mencapai 94.14%, serta nilai *precision*, *recall*, dan *f1-score* yang tinggi di hampir seluruh kelas. Hasil ini membuktikan bahwa CNN dengan arsitektur *ResNet50V2* mampu mengenali karakteristik visual dari masing-masing penyakit daun secara akurat, terlebih setelah melalui tahapan normalisasi, augmentasi data dan penggunaan data test yang tidak pernah dilibatkan dalam proses pelatihan maupun validasi. Grafik akurasi dan loss selama pelatihan juga menunjukkan kestabilan model tanpa indikasi *overfitting*.

Keberhasilan ini membuka peluang penerapan sistem deteksi penyakit tanaman berbasis citra digital di bidang pertanian. Sistem ini berpotensi membantu petani dalam mengenali penyakit daun padi dengan efektif, sehingga dapat mempercepat proses pengendalian.

Untuk saran dalam penelitian berikutnya selain menggunakan metode CNN, sebaiknya penelitian selanjutnya juga mencoba membandingkan dengan metode lain untuk melihat mana yang paling bagus hasilnya. Misalnya, bisa menggunakan model lain yang juga berbasis deep learning seperti *EfficientNet*, *MobileNet*, atau *DenseNet*, yang sama-sama dirancang untuk mengenali gambar. Selain itu, bisa juga mencoba metode machine learning seperti

Random Forest atau SVM, yang bekerja berdasarkan ciri-ciri khusus dari gambar, seperti bentuk dan teksturnya. Selain itu, disarankan agar penelitian selanjutnya mencakup jenis penyakit yang lebih beragam. Saat ini, klasifikasi masih terbatas pada beberapa jenis penyakit utama. Dengan memperluas cakupan jenis penyakit daun padi, atau bahkan mencakup tanaman lain, sistem yang dikembangkan akan menjadi lebih mudah diterapkan, lebih bermanfaat, dan dapat digunakan dalam berbagai kondisi pertanian yang berbeda.

DAFTAR PUSTAKA

- [1] B. A. Prastyo, I. Istiadi, and A. Y. Rahman, "Klasifikasi Penyakit Daun Padi Menggunakan Support Vector Machine Melalui Tekstur Dan Warna Daun Dengan Hsv Dan Gabor Filter," *ciastech*, vol. 6, no. 1, p. 567, Dec. 2023, doi: 10.31328/ciastech.v6i1.5348.
- [2] R. R. Burhanuddin, "Klasifikasi Penyakit Padi Melalui Citra Daun Menggunakan Metode Naive Bayes," *JITET*, vol. 12, no. 2, Apr. 2024, doi: 10.23960/jitet.v12i2.4012.
- [3] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *JBI*, vol. 13, no. 1, pp. 54–65, Apr. 2022, doi: 10.24002/jbi.v13i1.5022.
- [4] D. W. Rustanto, F. Liantoni, and N. P. T. Prakisy, "Identifikasi Penyakit Daun pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (KNN)," *justin*, vol. 12, no. 1, p. 100, Jan. 2024, doi: 10.26418/justin.v12i1.69752.
- [5] K. L. Kohsasih, M. D. A. Rizky, T. Fahriyani, V. Wijaya, and R. Rosnelly, "Analisis Perbandingan Algoritma Convolutional Neural Network Dan Algoritma Multi-Layer Perceptron Neural Dalam Klasifikasi Citra Sampah".
- [6] A. Nurdin, D. S. Yudha Kartika, and A. R. Efrat Najaf, "Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3," *oai*, vol. 12, no. 02, pp. 114–119, Sep. 2024, doi: 10.33884/jif.v12i02.9162.
- [7] A. J. Rozaqi, A. Sunyoto, and M. R. Arief, "Deteksi Penyakit Pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network," *citec*, vol. 8, no. 1, p. 22, Mar. 2021, doi: 10.24076/citec.2021v8i1.263.
- [8] B. S. Acarya, A. Muhaimin, and K. M. Hindrayani, "Identifikasi Penyakit Daun Jeruk Siam Menggunakan Convolutional Neural Network (CNN) dengan Arsitektur EfficientNet," *G-Tech*, vol. 8, no. 2, pp. 1040–1048, Apr. 2024, doi: 10.33379/gtech.v8i2.4120.
- [9] A. Yogyanto and A. Maulana, "Penerapan Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Penyakit Tanaman Jagung," vol. 3, 2024.
- [10] A. Achmadi, B. Akramul Umam, and A. Anwari, "Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode Convolutional Neural Network (CNN) Dan Metode Transfer Learning: Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode Convolutional Neural Network (CNN) Dan Metode Transfer Learning," *siskom-kb*, vol. 8, no. 1, pp. 10–16, Oct. 2024, doi: 10.47970/siskom-kb.v8i1.654.
- [11] J. Lu, L. Tan, and H. Jiang, "Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification," *Agriculture*, vol. 11, no. 8, p. 707, Jul. 2021, doi: 10.3390/agriculture11080707.
- [12] J. Cai *et al.*, "Improved EfficientNet for corn disease identification," *Front. Plant Sci.*, vol. 14, Sep. 2023, doi: 10.3389/fpls.2023.1224385.

- [13] T. S. Alam, C. B. Jowthi, and A. Pathak, "Comparing pre-trained models for efficient leaf disease detection: a study on custom CNN," *Journal of Electrical Systems and Inf Technol*, vol. 11, no. 1, Feb. 2024, doi: 10.1186/s43067-024-00137-1.
- [14] Paweekorns. (2025). Rice leaf diseases detection dataset. Kaggle. Diakses pada 19 maret 2025, dari https://www.kaggle.com/code/paweekorns/rice-disease-yolo/input?select=rice_leaf_diease
- [15] R. Ferdianysah, S. T. Arfian, and R. A. O. Syah, "Klasifikasi Penyakit Daun Pisang Berbasis Cnn Menggunakan Model Globalavaragepooling2d, Averagepooling, Dan Flatten," 2024.