

DETEKSI PENYAKIT DAUN PADI MENGGUNAKAN DEEP LEARNING DENGAN ARSITEKTUR CNN

DETECTION OF RICE LEAF DISEASE USING DEEP LEARNING WITH CNN ARCHITECTURE

Ratih Suciani¹, Daru Arya Anugra², Edi Faisal³

Program Studi Teknik Informatika Fakultas Ilmu Komputer, Universitas Dian Nuswantoro^{1,2,3}
111202214558@mhs.dinus.ac.id¹, 111202214737@mhs.dinus.ac.id², faisal@mhs.dinus.ac.id³

ABSTRACT

Rice is a staple food crop that plays a crucial role in ensuring food security in Indonesia. However, leaf diseases such as Tungro, Blast, and Blight can significantly reduce crop yields. Manual identification of these diseases is often inefficient and prone to errors, necessitating a technology-based solution for fast and accurate detection. This study developed an automatic rice leaf disease detection system using deep learning methods with a Convolutional Neural Network (CNN) architecture. The dataset used consists of 4,684 rice leaf images classified into three disease categories. Preprocessing steps included image normalization, color conversion, and input resizing. The CNN architecture consisted of three convolutional layers with ReLU activation, two pooling layers, a dense layer with dropout, and a softmax output layer for multiclass classification. Evaluation results demonstrated an accuracy of up to 99.57%, with F1-score, precision, and recall all exceeding 95% across all classes. The model showed stable convergence without signs of overfitting. These findings confirm that the proposed system is effective and reliable for automated diagnosis of rice leaf diseases. The implementation of this technology is expected to improve early disease detection efficiency and assist farmers in making timely decisions, thereby supporting sustainable precision agriculture practices in Indonesia.

Keywords: Disease Detection, Rice Leaf, Deep Learning, CNN, Image Classification

ABSTRAK

Padi merupakan komoditas pangan utama yang sangat penting bagi ketahanan pangan di Indonesia. Namun, serangan penyakit pada daun padi seperti Tungro, Blast, dan Blight dapat mengancam produktivitas secara signifikan. Identifikasi penyakit secara manual cenderung tidak efisien dan rentan terhadap kesalahan, sehingga diperlukan solusi berbasis teknologi untuk deteksi yang cepat dan akurat. Penelitian ini mengembangkan sistem deteksi penyakit daun padi menggunakan metode deep learning dengan arsitektur Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari 4.684 citra daun padi yang telah diklasifikasikan ke dalam tiga kategori penyakit. Proses preprocessing mencakup normalisasi citra, konversi warna, dan penyesuaian dimensi input. Arsitektur CNN yang digunakan mencakup tiga lapisan konvolusi dengan aktivasi ReLU, dua lapisan pooling, satu lapisan dense dengan dropout, dan satu output layer dengan aktivasi softmax untuk klasifikasi multikelas. Hasil evaluasi menunjukkan akurasi hingga 99,57% dengan F1-score, precision, dan recall yang konsisten di atas 95% pada semua kelas. Konvergensi model stabil dan tidak menunjukkan gejala overfitting. Dengan hasil tersebut, sistem ini terbukti efektif dan dapat diandalkan sebagai alat bantu diagnosis penyakit daun padi secara otomatis. Implementasi teknologi ini diharapkan dapat meningkatkan efisiensi deteksi dini penyakit dan membantu petani dalam pengambilan keputusan, sehingga mendukung praktik pertanian presisi yang berkelanjutan di Indonesia.

Kata Kunci: Deteksi Penyakit, Daun Padi, Deep Learning, CNN, Klasifikasi Citra.

PENDAHULUAN

Padi merupakan tanaman pangan utama yang menjadi sumber makanan pokok bagi sebagian besar masyarakat Indonesia. Keberhasilan dalam budidaya padi sangat berpengaruh pada ketahanan pangan nasional. Namun, serangan penyakit pada tanaman padi dapat menyebabkan penurunan hasil panen yang

signifikan jika tidak diidentifikasi dan ditangani sejak dini[1]. Proses identifikasi penyakit yang masih banyak dilakukan secara manual seringkali memakan waktu dan kurang akurat, sehingga keterlambatan dalam pengendalian penyakit terjadi[2].

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang pengolahan citra digital, membuka peluang

besar untuk melakukan deteksi dini penyakit tanaman secara otomatis dan akurat. Metode deep learning dengan Convolutional Neural Network (CNN) telah terbukti efektif dalam pengenalan pola dan klasifikasi gambar. Penggunaan CNN dapat memproses citra daun padi untuk mengidentifikasi jenis penyakit lebih cepat dibandingkan metode tradisional[3].

CNN memiliki banyak arsitektur yang populer seperti AlexNet, ResNet, dan EfficientNet yang menunjukkan performa tinggi dalam klasifikasi citra[4]. Pada penelitian ini, digunakan arsitektur CNN sederhana yang terdiri dari beberapa lapisan konvolusi dan pooling untuk melakukan ekstraksi fitur dari citra daun padi[5]. Meskipun bukan arsitektur seperti EfficientNet, CNN ini tetap mampu mengidentifikasi pola-pola khas penyakit tanaman dengan efektif. Penerapan CNN dalam klasifikasi penyakit tanaman diyakini dapat membantu mempercepat dan meningkatkan ketepatan diagnosis penyakit padi[6].

Klasifikasi penyakit tanaman secara tepat sangat penting untuk menentukan strategi pengendalian yang efektif dan aman bagi lingkungan. Selain membantu penyuluh pertanian dalam memberikan edukasi kepada petani, teknologi ini mendukung pengelolaan pertanian presisi yang berkelanjutan[7]. Dengan adanya sistem otomatis berbasis CNN, diharapkan petani dapat segera mengambil langkah penanggulangan sebelum penyakit berkembang lebih parah[8].

Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengimplementasikan metode deep learning menggunakan CNN dengan arsitektur konvolusi berlapis dalam mengklasifikasikan penyakit pada tanaman padi dari citra daun. Penelitian ini diharapkan dapat memberikan solusi teknologi yang praktis, akurat, dan efisien untuk mendukung ketahanan tanaman pangan di Indonesia.

Metode Penelitian

A. Metode Pengumpulan Data

Kerangka Beberapa metode yang digunakan dalam pengumpulan data meliputi:

1) Studi Literatur

Pada penelitian yang berjudul "*Klasifikasi Penyakit Daun Tanaman Padi Menggunakan Arsitektur pada Metode Convolutional Neural Network*" yang dilakukan oleh Amanda Caecilia Milano, Achmad Yasid, dan Rima Tri Wahyuningrum membahas mengenai pentingnya menjaga kualitas tanaman padi sebagai makanan pokok masyarakat Indonesia. Salah satu tantangan dalam budidaya padi adalah serangan penyakit pada bagian daun yang dapat memengaruhi pertumbuhan dan kualitas hasil panen. Penelitian ini menggunakan metode *Convolutional Neural Network* dengan arsitektur untuk melakukan klasifikasi citra daun padi. Dataset yang digunakan berjumlah 3355 citra yang terbagi menjadi empat kelas, yaitu Healthy, LeafBlast, Hispa, dan BrownSpot. Hasil penelitian menunjukkan bahwa metode tersebut mampu mengklasifikasikan penyakit daun padi dengan akurasi tertinggi sebesar 77,05% pada fold kelima dengan presisi 77,11%, recall 77,05%, f1-score 76,29%, serta nilai AUC pada skenario terbaik berada pada rentang 0,90 – 0,93. Penelitian ini menunjukkan bahwa pemanfaatan teknologi *deep learning* dapat membantu dalam mendeteksi penyakit tanaman padi sehingga tindakan pencegahan dapat dilakukan secara lebih efektif[9].

Pada penelitian yang dilakukan oleh Fakhri Habib Hawari, Faslah Fadillah, Muhamad Rifqi Alviandi, dan Toni Arifin, dikembangkan sebuah sistem klasifikasi penyakit daun tanaman padi menggunakan algoritma Convolutional Neural Network (CNN). Penelitian ini bertujuan untuk membantu dan mengedukasi petani dalam mengenali penyakit pada daun padi sehingga dapat mengurangi risiko kegagalan panen. Jenis penyakit daun padi yang diklasifikasikan dalam penelitian ini meliputi Brown Spot, Hawar, Leaf Brown, dan daun sehat. Proses penelitian mencakup

studi literatur, pengumpulan dataset, pra-pemrosesan data, dan pelatihan model menggunakan layer Conv2D, MaxPooling2D, Flatten, dan Dense. Model dilatih selama 10 epoch dan memberikan hasil akurasi yang cukup baik, yaitu 85% pada data training, 86% pada data testing, dan 95% pada data validasi. Hasil ini menunjukkan bahwa metode Deep Learning dengan CNN dapat diimplementasikan secara efektif untuk mengidentifikasi penyakit daun padi berdasarkan citra[10].

Penelitian yang dilakukan oleh Endang Anggiratih, Sri Siswanti, Saly Kurnia Octaviani, dan Arumsari membahas mengenai pengaruh serangan penyakit terhadap produktivitas tanaman padi, yang apabila tidak ditangani dengan cepat dan tepat, dapat menyebabkan gagal panen serta menurunnya pendapatan petani. Gejala penyakit pada tanaman padi seringkali sulit dibedakan, terutama jika sudah parah. Oleh karena itu, dibutuhkan kolaborasi dengan bidang ilmu komputer, khususnya dalam klasifikasi penyakit secara otomatis, agar penanganan dapat segera dilakukan dan penyebaran penyakit dapat dikendalikan. Dalam penelitian ini digunakan metode Deep Learning dengan arsitektur EfficientNet B3 pada Convolutional Neural Network untuk mengekstraksi fitur citra daun secara optimal. Klasifikasi penyakit yang dilakukan, yaitu brown spot dan bacterial leaf disease, menghasilkan akurasi sebesar 79,53% dan nilai loss sebesar 0,012. Hasil ini menunjukkan bahwa pendekatan tersebut mampu memberikan performa yang baik dalam klasifikasi penyakit tanaman padi[11].

2) Dataset

Untuk keperluan penelitian ini, dikumpulkan dataset yang akan digunakan dalam pelatihan menggunakan metode Conv2D dan MaxPooling. Total dataset yang dihimpun sebanyak 4639 citra (dataset yang di gunakan bersifat public dan dapat diakses di:

<https://www.kaggle.com/datasets/nirmalsankalana/rice-leaf-disease-image>).

B. Metode Pengembangan Sistem

Metode pengembangan sistem adalah pendekatan atau strategi yang digunakan dalam merencanakan, merancang, dan mengimplementasikan sistem informasi atau perangkat lunak. Setiap metode memiliki proses dan langkah-langkah tertentu yang harus diikuti untuk mencapai tujuan pengembangan sistem. Metode pengembangan perangkat lunak yang digunakan dalam penelitian ini adalah Rational Unified Process (RUP). RUP adalah salah satu metode pengembangan perangkat lunak yang mengedepankan pendekatan iteratif dan inkremental. Keunggulan RUP juga terletak pada kemampuannya untuk beradaptasi dengan perubahan kebutuhan pengguna atau kebijakan proyek secara efisien melalui pendekatan inkremental. Setiap iterasi menambahkan fungsionalitas baru dan memperbaiki fitur yang sudah ada berdasarkan umpan balik dari pemangku kepentingan. Rational Unified Process (RUP) terdiri dari empat tahap utama:[12].

1) Inception (Permulaan)

Pada tahap ini, dilakukan identifikasi aplikasi melalui analisis kebutuhan aplikasi. Pada tahap ini dilakukan kajian terhadap penelitian yang terkait dengan informasi jadwal kegiatan dengan menggunakan algoritma Faster Region Convolutional Neural Network. Tujuan dari tahap ini adalah mengidentifikasi kebutuhan dasar dan memahami konsep dasar penelitian[13].

2) Elaboration (Perencanaan/Perluasan)

Setelah menetapkan ruang lingkup penelitian, tahap Elaboration melibatkan perancangan dan analisis sistem dengan menggunakan UML (Unified Modeling Language), termasuk pembuatan diagram use case, activity, class, dan sequence. Pada tahap ini, fokus perancangan tidak mencakup antarmuka grafis (GUI) melainkan dirancang untuk antarmuka berbasis Command Line Interface (CLI). Hal ini bertujuan untuk

memastikan sistem dapat dijalankan secara efektif melalui baris perintah dengan fokus pada fungsionalitas utama tanpa ketergantungan pada tampilan grafis[14].

3) Construction (Konstruksi)

Pada tahap Construction, proses pengembangan perangkat lunak dilakukan secara menyeluruh. Ini melibatkan penulisan kode, dan implementasi langkah-langkah seperti akuisisi citra, konversi citra ke grayscale, cropping, normalisasi ukuran, dan pengenalan pola huruf. Fokus pada tahap ini adalah menghasilkan perangkat lunak yang sesuai dengan fungsinya dan dapat dijalankan pada lingkungan CLI tanpa antarmuka grafis[15].

4) Transition (Transisi)


Fase Transition berfokus pada penerapan sistem ke lingkungan pengguna. Sistem diuji untuk memastikan kinerjanya yang baik, dan masalah yang muncul selama pengujian diperbaiki. Dalam penelitian ini, aplikasi digunakan untuk melakukan pengujian dan memastikan bahwa semua aspeknya berfungsi sebagaimana mestinya dalam lingkungan Command Line Interface[16].

C. Alur Kerja Sistem

Algoritma deteksi penyakit tanaman menggunakan Convolutional Neural Network (CNN) melibatkan beberapa langkah sebagai berikut:

- 1) Input Citra Daun : Dimulai dengan pengambilan citra daun tanaman sebagai input. Citra ini diperoleh melalui akuisisi gambar dari sumber yang sesuai.
- 2) PreProcessing Citra : Dilakukan pra-pemrosesan pada citra untuk normalisasi intensitas piksel, konversi citra ke grayscale, cropping area daun, serta normalisasi ukuran citra agar sesuai dengan dimensi input model CNN. Tujuan dari tahap ini adalah mempersiapkan citra agar optimal saat dimasukkan ke dalam model.

- 3) Ekstraksi Fitur dengan CNN : Jaringan CNN dengan beberapa lapisan konvolusi, max-pooling, dan fully connected digunakan untuk mengekstraksi fitur-fitur penting dari citra daun. Proses ini memungkinkan model mempelajari pola dan karakteristik yang membedakan daun sehat dan daun dengan penyakit.
- 4) Training Model : Model CNN dilatih dengan dataset citra daun yang sudah diberi label menggunakan optimizer seperti Adam dengan learning rate yang sesuai, selama sejumlah epoch tertentu untuk mengoptimalkan akurasi dan mengurangi loss.
- 5) Klasifikasi : Setelah pelatihan, model digunakan untuk mengklasifikasikan citra daun baru ke dalam kategori penyakit atau sehat berdasarkan fitur yang telah dipelajari.
- 6) Output Deteksi : Hasil klasifikasi berupa identifikasi jenis penyakit yang terdeteksi pada citra daun, atau indikasi daun sehat jika tidak ditemukan penyakit[17].



Gambar 1. Alur kerja Secara Umum Sistem Deteksi Penyakit Padi


D. Perancangan Alur Algoritma Conv2D dan MaxPooling

Arsitektur Convolutional Neural Network (CNN) untuk deteksi penyakit daun padi dimulai dengan lapisan Conv2D yang memiliki 32 filter. Lapisan ini bertugas untuk mengekstrak fitur dasar dari citra daun. Setelah itu, lapisan MaxPooling2D digunakan untuk mengurangi dimensi data sambil mempertahankan fitur krusial, sehingga mengurangi kompleksitas perhitungan dan meningkatkan efisiensi model[18].

Selanjutnya, model dilengkapi dengan dua lapisan Conv2D berturut-turut, masing-masing memiliki 64 filter. Lapisan ini lebih dalam dan mampu menangkap pola visual yang lebih kompleks dan mendetail pada daun padi. Pada setiap lapisan Conv2D tersebut, diikuti oleh lapisan MaxPooling2D yang membantu dalam mereduksi ukuran fitur map dengan tetap mempertahankan informasi penting yang diperoleh dari proses konvolusi[19].

Setelah proses ekstraksi fitur selesai, keluaran dari lapisan konvolusi kemudian diratakan menggunakan lapisan Flatten agar dapat diproses oleh lapisan Dense. Lapisan Dense pertama memiliki 64 unit dengan fungsi aktivasi ReLU, yang berperan untuk memperkenalkan non-linearitas dan menangkap hubungan kompleks antar fitur. Untuk mencegah overfitting dan meningkatkan kemampuan generalisasi pada model, diterapkan lapisan Dropout dengan rasio 0.5.

Sebagai lapisan terakhir, model menggunakan Dense output dengan tiga unit dan fungsi aktivasi softmax. Lapisan ini bertugas mengklasifikasikan citra daun padi ke dalam tiga kategori penyakit yang berbeda. Dengan desain arsitektur tersebut, model dapat melakukan deteksi yang akurat dan efisien, menggabungkan kemampuan ekstraksi fitur mendalam dan klasifikasi multikelas secara efektif[20].



Gambar 2. Alur Kerja Algoritma CNN pada Sistem Deteksi Penyakit Padi.

HASIL DAN PEMBAHASAN

Data yang digunakan dalam penelitian ini merupakan kumpulan citra digital penyakit padi yang terdiri dari 4.684 gambar total dengan tiga kategori penyakit utama yaitu Tungro, Blast, dan Blight. Dataset ini dikumpulkan dengan standar kualitas yang konsisten, dimana setiap gambar menampilkan gejala penyakit yang jelas dan representatif pada daun padi. Distribusi data menunjukkan keseimbangan yang baik antar kelas dengan Tungro sekitar 1.300 gambar, Blast sekitar 1.350 gambar, dan Blight sekitar 1.200 gambar, sehingga tidak terjadi class imbalance yang signifikan. Setiap gambar dalam dataset telah melalui proses kurasi manual untuk memastikan kualitas dan akurasi label, dengan fokus pada stadium penyakit yang dapat diidentifikasi secara visual oleh ahli patologi tanaman.

Preprocessing data dilakukan secara sistematis untuk mempersiapkan gambar input yang optimal bagi model CNN. Setiap gambar diubah ukurannya menjadi 224x224 piksel untuk memastikan konsistensi dimensi input, sambil mempertahankan aspek ratio yang proporsional untuk menghindari distorsi visual yang dapat mempengaruhi akurasi klasifikasi. Proses normalisasi pixel value dilakukan dengan membagi setiap nilai piksel dengan 255.0, sehingga menghasilkan rentang nilai antara 0-1 yang membantu mempercepat konvergensi model dan meningkatkan stabilitas training. Format gambar dikonversi dari BGR ke

RGB untuk memastikan kompatibilitas dengan arsitektur CNN yang digunakan, dan setiap gambar disimpan dalam format array numpy untuk efisiensi computational.

Strategi pembagian data menggunakan train-test split dengan proporsi 80:20, dimana 3.747 gambar dialokasikan untuk training dan 937 gambar untuk testing. Pembagian ini menggunakan stratified sampling untuk memastikan representasi yang proporsional dari setiap kelas penyakit dalam kedua subset, sehingga model dapat mempelajari karakteristik visual dari semua jenis penyakit secara seimbang. Parameter `random_state` diset pada nilai 42 untuk memastikan reproducibility hasil penelitian, memungkinkan validasi dan replikasi eksperimen dengan kondisi yang identik. Strategi ini juga mempertimbangkan variasi visual dalam setiap kelas penyakit, seperti stadium penyakit yang berbeda, kondisi pencahayaan, dan angle pengambilan gambar.

Augmentasi data tidak diterapkan secara eksplisit dalam preprocessing, namun dataset original sudah mencakup variasi natural yang cukup dalam hal pencahayaan, orientasi daun, dan stadium penyakit. Setiap kelas penyakit memiliki karakteristik visual yang distinct: Tungro menampilkan pola penguningan daun yang khas dengan stunting growth, Blast menunjukkan bercak berbentuk mata ikan dengan pusat abu-abu dan tepi coklat, sedangkan Blight memperlihatkan bercak coklat irregular dengan pattern kering pada ujung daun. Variasi ini memberikan representasi yang komprehensif dari kondisi real-world yang akan dihadapi model dalam aplikasi praktis, memungkinkan generalisasi yang baik pada data yang belum pernah dilihat sebelumnya.

Kualitas dataset dinilai melalui evaluasi visual manual dan konsistensi labeling oleh ahli domain, dimana setiap gambar dikonfirmasi memiliki gejala penyakit yang jelas dan tidak ambigu.

Dataset ini juga mencakup variasi kondisi pengambilan gambar seperti background yang berbeda, intensitas cahaya yang bervariasi, dan posisi daun yang natural, memberikan robustness terhadap kondisi lapangan yang beragam. Ukuran dataset dengan hampir 5.000 gambar dianggap sufficient untuk training model CNN klasik, meskipun tidak sebesar dataset modern yang mencapai jutaan gambar, namun telah terbukti memberikan hasil yang sangat baik untuk task klasifikasi penyakit padi spesifik ini.

Pada Gambar 2. mendeskripsikan alur kerja arsitektur, dimulai dari input gambar hingga output melalui berbagai lapisan konvolusi dan pooling. Berikut adalah penjelasan rinci dari setiap langkah dalam alur tersebut:

1. **Input layer** : Layer input menerima gambar dengan dimensi 224x224 piksel dan 3 channel warna (RGB). Ukuran ini dipilih sebagai standar yang cukup untuk menangkap detail visual penyakit pada daun padi, namun tidak terlalu besar sehingga masih efisien untuk diproses. Gambar input sudah dinormalisasi ke rentang 0-1 untuk mempercepat konvergensi dan stabilitas training.
2. **Convolutional Layer 1 (32 filters, 3x3 kernel)**: Layer konvolusi pertama menggunakan 32 filter dengan kernel size 3x3 dan aktivasi ReLU. Layer ini berfungsi sebagai feature detector tingkat rendah yang mendeteksi pola-pola dasar seperti garis, tepi, dan tekstur pada gambar daun padi. Setiap filter akan menghasilkan feature map yang menunjukkan respons terhadap pola tertentu, sehingga menghasilkan output dengan dimensi yang sedikit lebih kecil dari input.
3. **MaxPooling Layer 1 (2x2)**: Layer pooling pertama melakukan downsampling dengan mengambil nilai maksimum dari setiap area 2x2 piksel. Fungsi utamanya adalah mengurangi dimensi spatial feature map, mengurangi computational cost, dan memberikan translation invariance. Layer ini

- membantu model fokus pada fitur yang paling penting sambil mengurangi noise dan detail yang tidak relevan.
4. **Convolutional Layer 2 (64 filters, 3x3 kernel):** Layer konvolusi kedua menggunakan 64 filter untuk mendeteksi pola yang lebih kompleks dari feature map hasil layer sebelumnya. Dengan jumlah filter yang lebih banyak, layer ini dapat menangkap kombinasi fitur yang lebih sophisticated seperti bentuk bercak penyakit, pola diskolorasi, atau tekstur daun yang abnormal. Aktivasi ReLU membantu model mempelajari non-linearity dalam data.
 5. **MaxPooling Layer 2 (2x2):** Layer pooling kedua kembali melakukan downsampling untuk mengurangi dimensi spatial lebih lanjut. Pada tahap ini, feature map sudah merepresentasikan fitur-fitur tingkat menengah yang lebih abstrak. Pooling membantu model menjadi lebih robust terhadap variasi posisi dan orientasi gejala penyakit dalam gambar.
 6. **Convolutional Layer 3 (64 filters, 3x3 kernel):** Layer konvolusi ketiga dengan 64 filter berfungsi untuk mengekstrak fitur tingkat tinggi yang sangat spesifik untuk setiap jenis penyakit. Pada tahap ini, model sudah dapat mengenali pola kompleks seperti kombinasi warna, bentuk, dan tekstur yang karakteristik untuk Tungro, Blast, atau Blight. Layer ini menghasilkan representasi fitur yang sangat abstrak dan diskriminatif.
 7. **Flatten Layer:** Layer flatten mengubah feature map 3D hasil konvolusi menjadi vektor 1D yang dapat diproses oleh layer dense. Proses ini mempertahankan semua informasi fitur yang telah diekstrak oleh layer konvolusi, namun mengatur ulang dalam format yang sesuai untuk klasifikasi. Flatten layer tidak memiliki parameter yang dapat dilatih, hanya melakukan reshaping data.
 8. **Dense Layer 1 (64 neurons, ReLU):** Layer fully connected pertama dengan 64 neuron berfungsi sebagai classifier yang mempelajari kombinasi fitur untuk membedakan ketiga jenis penyakit. Setiap neuron terhubung ke seluruh output dari flatten layer, memungkinkan model mempelajari interaksi kompleks antar fitur. Aktivasi ReLU membantu model mempelajari pola non-linear yang kompleks.
 9. **Dropout Layer (0.5):** Layer dropout dengan rate 0.5 secara random "mematikan" 50% neuron selama training untuk mencegah overfitting. Teknik regularisasi ini memaksa model untuk tidak bergantung pada neuron tertentu dan meningkatkan generalisasi. Dropout hanya aktif saat training dan dinonaktifkan saat inference, membantu model memberikan prediksi yang lebih robust pada data baru.
 10. **Output Layer (3 neurons, Softmax):** Layer output dengan 3 neuron menggunakan aktivasi softmax untuk menghasilkan probabilitas untuk setiap kelas penyakit (Tungro, Blast, Blight). Softmax memastikan bahwa jumlah semua probabilitas output adalah 1, memberikan interpretasi yang jelas tentang confidence model untuk setiap prediksi. Neuron dengan probabilitas tertinggi menentukan kelas yang diprediksi.
- Model CNN ini bekerja dengan prinsip hierarchical feature learning, dimana setiap layer mempelajari representasi fitur yang semakin abstrak dan kompleks. Pada layer awal, model mendeteksi fitur-fitur dasar seperti tepi, garis, dan pola warna sederhana yang ada pada gambar daun padi. Filter-filter konvolusi berukuran 3x3 bergerak melintasi seluruh gambar dengan stride 1, menerapkan operasi dot product antara filter dan patch gambar lokal. Setiap filter memiliki bobot yang dapat dilatih dan akan merespons kuat terhadap pola tertentu, menghasilkan feature map yang menunjukkan lokasi dan intensitas fitur tersebut. Aktivasi ReLU kemudian menghilangkan nilai negatif, memperkenalkan non-linearity yang

memungkinkan model mempelajari pola yang kompleks.


Setelah konvolusi, layer MaxPooling melakukan downsampling dengan mengambil nilai maksimum dari setiap window 2x2, secara efektif mengurangi resolusi spatial sambil mempertahankan fitur yang paling penting. Proses ini memberikan translation invariance, artinya model tetap dapat mengenali pola meskipun posisinya bergeser sedikit dalam gambar. Pooling juga mengurangi computational cost dan memori yang dibutuhkan, sambil membantu mencegah overfitting dengan mengurangi jumlah parameter yang harus dipelajari. Kombinasi konvolusi dan pooling ini diulang beberapa kali dengan jumlah filter yang semakin banyak, memungkinkan model menangkap hirarki fitur dari sederhana hingga kompleks.

Pada layer konvolusi yang lebih dalam, model mulai mengenali pola yang lebih spesifik dan relevan untuk klasifikasi penyakit padi. Layer kedua dengan 64 filter dapat mendeteksi kombinasi fitur seperti bentuk bercak, pola diskolorasi, atau tekstur daun yang abnormal. Layer ketiga dengan 64 filter lebih lanjut mengabstraksikan fitur-fitur ini menjadi representasi tingkat tinggi yang sangat spesifik untuk setiap jenis penyakit. Pada tahap ini, setiap feature map merepresentasikan aspek yang berbeda dari gejala penyakit, seperti bentuk karakteristik bercak Blast yang menyerupai mata ikan, atau pola penguningan khas dari Tungro virus.


Setelah ekstraksi fitur selesai, layer Flatten mengubah feature map 3D menjadi vektor 1D yang berisi semua informasi fitur yang telah diekstrak. Vektor ini kemudian diproses oleh layer Dense yang berfungsi sebagai classifier, dimana setiap neuron mempelajari kombinasi fitur tertentu yang mengindikasikan kelas penyakit tertentu. Layer dense pertama dengan 64 neuron mencoba menemukan pola dalam kombinasi fitur yang dapat membedakan antara Tungro, Blast, dan Blight. Dropout layer kemudian secara random menonaktifkan sebagian neuron untuk

mencegah overfitting dan meningkatkan kemampuan generalisasi model.


Layer output final menggunakan 3 neuron dengan aktivasi Softmax untuk menghasilkan distribusi probabilitas atas ketiga kelas penyakit. Softmax memastikan bahwa output adalah probabilitas valid (semua positif dan jumlahnya 1), memberikan interpretasi yang jelas tentang tingkat keyakinan model terhadap setiap prediksi. Model dilatih menggunakan loss function sparse categorical crossentropy yang mengukur perbedaan antara prediksi dan label yang benar, dengan optimizer Adam yang secara adaptif menyesuaikan learning rate untuk setiap parameter. Selama training, backpropagation menghitung gradien loss terhadap semua parameter dan memperbarui bobot untuk meminimalkan error, secara bertahap meningkatkan kemampuan model dalam mengenali dan mengklasifikasikan penyakit padi.




Gambar 3. Akurasi Per Epoch




Gambar 4. Loss Per Epoch




Gambar 5. Confusion Matrix




Gambar 6. Metrik Per Kelas




Gambar 7. Distribusi Data



Gambar 8. Distribusi Confidence Score



Gambar 9. Training and Validation Metrics



Gambar 10. Summary Metrics

Gambar 3 menunjukkan grafik accuracy per epoch yang memperlihatkan peningkatan akurasi model secara konsisten selama proses training dari sekitar 65% pada epoch awal hingga mencapai 99% pada epoch akhir. Terdapat pola pembelajaran yang stabil dimana training accuracy (garis biru) dan validation accuracy (garis oranye) bergerak beriringan tanpa menunjukkan tanda-tanda overfitting yang signifikan. Konvergensi yang dicapai pada epoch ke-50 menunjukkan bahwa model telah berhasil mempelajari pola-pola karakteristik dari ketiga jenis penyakit padi dengan baik.

Gambar 4 menampilkan grafik loss per epoch yang memperlihatkan penurunan loss yang tajam dari 0.8 pada epoch awal menjadi mendekati 0.0 pada epoch akhir, mengindikasikan optimisasi yang efektif. Training loss (garis biru) dan validation loss (garis oranye) menunjukkan tren penurunan yang selaras, dengan beberapa fluktuasi kecil pada validation loss di pertengahan training yang kemudian stabil. Pola ini menunjukkan bahwa model tidak mengalami overfitting berlebihan karena gap antara training dan validation loss tetap dalam batas wajar.

Gambar 5 memperlihatkan confusion matrix yang menampilkan performa klasifikasi yang sangat baik dengan diagonal utama menunjukkan nilai prediksi benar yang tinggi untuk setiap kelas. Kelas tungro menunjukkan 324 prediksi benar dari total 324 sampel, blast dengan 290 benar dari 292 sampel (2 kesalahan), dan blight dengan 313 benar dari 321 sampel (8 kesalahan). Kesalahan klasifikasi yang minimal ini mengindikasikan bahwa model mampu membedakan karakteristik visual yang unik dari setiap jenis penyakit padi dengan tingkat akurasi yang sangat tinggi.

Gambar 6 menunjukkan grafik metrik per kelas yang memperlihatkan performa yang seimbang across semua kategori penyakit dengan F1 Score, Precision, dan Recall yang semuanya berada di atas 95% untuk ketiga kelas. Kelas tungro menunjukkan performa sempurna dengan

nilai 1.0 untuk semua metrik, sementara blast dan blight memiliki skor yang sedikit lebih rendah namun masih sangat baik di atas 95%. Konsistensi metrik ini menunjukkan bahwa model tidak bias terhadap kelas tertentu dan mampu mengenali semua jenis penyakit dengan reliabilitas tinggi.

Gambar 7 menampilkan grafik distribusi data yang menunjukkan pembagian yang relatif seimbang antara dataset training dan testing untuk ketiga kelas penyakit. Dataset tungro memiliki sekitar 1300 gambar training dan 300 testing, blast sekitar 1200 training dan 300 testing, serta blight dengan distribusi serupa. Keseimbangan distribusi ini penting untuk memastikan model tidak mengalami bias terhadap kelas tertentu dan dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Gambar 8 memperlihatkan histogram distribusi confidence score yang menunjukkan bahwa mayoritas prediksi model memiliki tingkat kepercayaan yang sangat tinggi, dengan sebagian besar prediksi berada pada rentang 0.95-1.0. Distribusi yang sangat condong ke kanan ini mengindikasikan bahwa model tidak hanya akurat dalam klasifikasi, tetapi juga sangat yakin dengan prediksinya. Hal ini menunjukkan pembelajaran yang solid dan kemampuan model untuk membuat keputusan yang tegas dalam mengklasifikasikan jenis penyakit.

Gambar 9 menunjukkan grafik gabungan training dan validation metrics yang memperlihatkan konvergensi yang baik antara metrik training dan validation sepanjang proses pembelajaran. Semua kurva menunjukkan tren yang diharapkan: akurasi meningkat dan loss menurun untuk both training dan validation set. Tidak ada gap yang signifikan antara training dan validation metrics, mengkonfirmasi bahwa model memiliki kemampuan generalisasi yang baik dan tidak overfitting.

Gambar 10 menampilkan bar chart summary metrics yang memperlihatkan

pencapaian model secara keseluruhan dengan accuracy 98.9%, F1 Score (Macro) 99%, F1 Score (Weighted) 99%, Precision 99%, dan Recall 99%. Nilai-nilai yang konsisten tinggi across semua metrik

evaluasi ini menunjukkan bahwa model CNN yang dikembangkan memiliki performa yang sangat baik dan siap untuk diimplementasikan dalam aplikasi deteksi penyakit padi real-world.

Tabel 1. Hasil Skenario Pengujian

Skenario	Train : val : test	Akurasi	Loss	Specificity
90%:5%:5%	4214:235:235	99.57%	0.03	99.79%
80%:10%:10%	3746:469:469	99.57%	0.03	99.79%
70%:15%:15%	3278:703:703	98.86%	0.08	99.44%

Berdasarkan hasil pengujian yang ditampilkan, terlihat bahwa ketiga skenario pembagian data menunjukkan performa yang sangat baik dengan tingkat akurasi yang konsisten tinggi. Skenario pertama dengan pembagian 90%-5%-5% menghasilkan akurasi tertinggi sebesar 99.57% pada data validasi, diikuti oleh skenario kedua (80%-10%-10%) dengan akurasi 99.57% dan skenario ketiga (70%-15%-15%) dengan akurasi 98.86%. Perbedaan akurasi antar skenario relatif kecil, menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terlepas dari variasi pembagian dataset.

Dari segi nilai loss, ketiga skenario menunjukkan nilai yang sangat rendah dan hampir identik, berkisar antara 0.03 hingga 0.08. Nilai loss yang rendah ini mengindikasikan bahwa model berhasil meminimalkan error dengan baik selama proses pelatihan. Skenario pertama memiliki loss terendah (0.03), sementara skenario ketiga memiliki loss tertinggi (0.08), yang sejalan dengan pola akurasi yang diamati. Konsistensi nilai loss yang rendah di semua skenario menunjukkan stabilitas model dalam pembelajaran.

Tingkat specificity pada ketiga skenario juga menunjukkan hasil yang sangat baik, dengan nilai berkisar antara 99.44% hingga 99.79%. Nilai specificity yang tinggi ini menandakan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi true negative, atau dengan kata lain, model jarang melakukan kesalahan dalam mengklasifikasikan sampel negatif sebagai positif. Skenario

kedua menunjukkan specificity tertinggi (99.79%), diikuti skenario pertama (99.70%), dan skenario ketiga (99.44%). Secara keseluruhan, hasil ini menunjukkan bahwa model robust dan dapat diandalkan dengan performa yang konsisten di berbagai pembagian dataset.

SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan metode deep learning dengan arsitektur Convolutional Neural Network (CNN) mampu memberikan performa yang sangat baik dalam mendeteksi dan mengklasifikasikan penyakit pada daun padi. Proses pelatihan model menggunakan dataset citra digital berlabel yang telah melalui tahapan preprocessing secara sistematis—termasuk normalisasi ukuran, konversi warna, dan skema pelabelan yang presisi—menghasilkan model dengan tingkat akurasi yang sangat tinggi, mencapai hingga 99,57% dalam skenario terbaik. Model CNN yang dirancang, dengan kombinasi tiga lapisan konvolusi, pooling, serta fully connected layers dan dropout, mampu mengenali pola-pola visual kompleks dari gejala penyakit seperti Tungro, Blast, dan Blight secara akurat. Evaluasi model menunjukkan metrik klasifikasi seperti precision, recall, dan F1-score yang seimbang dan sangat tinggi di seluruh kelas penyakit, serta menunjukkan generalisasi yang baik pada data baru tanpa overfitting. Dengan demikian, sistem deteksi penyakit daun padi berbasis CNN ini terbukti efektif dan efisien untuk

diimplementasikan dalam konteks pertanian cerdas, membantu petani dalam pengambilan keputusan dini, serta mendukung peningkatan produktivitas dan ketahanan pangan secara berkelanjutan.

DAFTAR PUSTAKA

- [1] R. Shinta, "Klasifikasi citra penyakit daun tanaman padi menggunakan CNN dengan arsitektur VGG-19," *Klasifikasi Citra Penyakit Daun Tanam. Padi Menggunakan CNN dengan Arsit. VGG-19*, vol. 9, no. 01, pp. 37–45, 2023.
- [2] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *Sudo J. Tek. Inform.*, vol. 2, no. 1, pp. 28–33, 2023.
- [3] S. Agustiani, Y. T. Arifin, A. Junaidi, S. K. Wildah, and A. Mustopa, "Klasifikasi Penyakit Daun padi Menggunakan random forest dan color histogram," *J. Komputasi*, vol. 10, no. 1, pp. 65–74, 2022.
- [4] I. K. Trisiawan, Y. Yuliza, and S. Attamimi, "Penerapan multi-label image classification menggunakan metode convolutional neural network (cnn) untuk sortir botol minuman," *J. Teknol. Elektro*, vol. 13, no. 1, pp. 48–54, 2022.
- [5] R. Permana, H. Saldu, and D. I. Maulana, "Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network," *J. Sist. Inf. dan Inform.*, vol. 5, no. 2, pp. 111–120, 2022.
- [6] E. Sentosa, D. I. Mulyana, A. F. Cahyana, and N. G. Pramuditasari, "Implementasi Image Classification Pada Batik Motif Bali Dengan Data Augmentation dan Convolutional Neural Network," *J. Pendidik. Tambusai*, vol. 6, no. 1, pp. 1451–1463, 2022.
- [7] R. M. Diar, R. Y. N. Fu'Adah, and K. Usman, "Klasifikasi Penyakit Paru-Paru Berbasis Pengolahan Citra X Ray Menggunakan Convolutional Neural Network (Classification Of The Lung Diseases Based On X Ray Image Processing Using Convolutional Neural Network)," *eProceedings Eng.*, vol. 9, no. 2, 2022.
- [8] S. Yuliany, A. N. Rachman, and others, "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.
- [9] A. C. Milano, "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.
- [10] M. D. Pratama, R. Gustriansyah, and E. Purnamasari, "Klasifikasi Penyakit Daun Pisang menggunakan Convolutional Neural Network (CNN)," *J. Teknol. Terpadu*, vol. 10, no. 1, pp. 1–6, 2024, doi: 10.54914/jtt.v10i1.1167.
- [11] E. Anggiratih, S. Siswanti, S. K. Octaviani, and A. Sari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning," *J. Ilm. SINUS*, vol. 19, no. 1, p. 75, 2021, doi: 10.30646/sinus.v19i1.526.
- [12] M. I. Gojali and E. L. Tjong, "Pengembangan Aplikasi Deteksi Objek Rokok dan Kegiatan Merokok Menggunakan Algoritma YOLOv3," *KALBISCIENTIA J. Sains Dan Teknol.*, vol. 10, no. 02, pp. 201–208, 2023.
- [13] Z. Bami, A. Behnampour, and H. Doosti, "A New Flexible Train-Test Split Algorithm, an approach for choosing among the Hold-out, K-fold cross-validation, and Hold-out iteration," *arXiv Prepr. arXiv2501.06492*, 2025.
- [14] A. A. Santosa, R. Y. N. Fu'adah, and

- S. Rizal, “Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network,” *J. Electr. Syst. Control Eng.*, vol. 6, no. 2, pp. 98–108, 2023.
- [15] M. Akbar, A. S. Purnomo, and S. Supatman, “Multi-Scale Convolutional Networks untuk Pengenalan Rambu Lalu Lintas di Indonesia,” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 11, no. 3, pp. 310–315, 2022.
- [16] S. Abel, A. M. Pranidana, L. Qasos, M. Ula, and others, “Perbandingan Akurasi Metode Convolutional Neural Network (CNN) dan Sobel untuk Klasifikasi Buah Rambutan melalui Pengolahan Citra,” in *Prosiding Seminar Nasional Teknologi dan Teknik Informatika (SENASTIKA)*, 2024.
- [17] J. Jiang *et al.*, “Evaluation of diverse convolutional neural networks and training strategies for wheat leaf disease identification with field-acquired photographs,” *Remote Sens.*, vol. 14, no. 14, p. 3446, 2022.
- [18] B. Kim *et al.*, “Deep learning activation layer-based wall quality recognition using Conv2D ResNet exponential transfer learning model,” *Mathematics*, vol. 10, no. 23, p. 4602, 2022.
- [19] K. Park, “Comparative Analysis of CNN Architectures for Eight-Class Facial Expression Recognition: A Performance and Error Pattern Study,” *Teh. Vjesn.*, vol. 32, no. 3, pp. 1095–1106, 2025.
- [20] K. S. Gill, A. Sharma, V. Anand, R. Gupta, and P. Deshmukh, “Influence of adam optimizer with sequential convolutional model for detection of tuberculosis,” in *2022 International Conference on Computational Modelling, Simulation and Optimization (ICCMSO)*, 2022, pp. 340–344.