

KLASIFIKASI PENYAKIT DAUN PADI BERBASIS CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DENGAN ARSITEKTUR VGG-16

Fuad Bawazir¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Puji Pramudya Marta⁴;

Program Studi Teknik Informatika¹
Program Studi Manajemen Informatika^{2,4}
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
bawazirfuad08@gmail.com

(*) Corresponding Author : bawazirfuad08@gmail.com
Received: date; Accepted: date; Published: date

Abstract— Rice leaf diseases are among the major factors that reduce agricultural productivity in Indonesia. Early and accurate identification is crucial to ensure that appropriate control measures can be implemented in a timely manner. However, manual identification performed by farmers and field officers is often constrained by limited expertise, inconsistent image quality, and high visual variability among symptoms. To address these challenges, this study develops a rice leaf disease detection model using digital images based on the VGG-16 Convolutional Neural Network (CNN) architecture, designed to automatically recognize disease patterns with high consistency. The main problems arise from the limited dataset size, variations in lighting and leaf orientation, as well as visual similarity between diseases such as Leaf Smut, Brown Spot, and Bacterial Leaf Blight, which often lead to misclassification. To overcome these limitations, the study applies several preprocessing steps including image resizing, pixel normalization, and augmentation techniques such as rotation, zooming, shifting, and shearing to enhance the robustness of the model against diverse image conditions. The VGG-16 model utilizes transfer learning and includes a customized fully connected layer tailored to classify the three disease categories. The results indicate that the CNN model achieves an overall accuracy of 75%, with the highest performance observed in the Bacterial Leaf Blight class (precision 0.88, recall 0.88), while Brown Spot remains the most challenging due to its highly variable lesion patterns. The confusion matrix confirms that most predictions fall into the correct classes, although misclassifications still occur in visually similar categories. The implications of this study highlight the potential use of CNN-based models as rapid diagnostic tools in agriculture, especially when integrated into mobile applications or IoT monitoring systems, enabling farmers to make more informed and efficient decisions in managing crop diseases.

Keywords : Convolutional Neural Network, VGG-16, Rice Leaf Disease Detection, Image Augmentation, Image Classification

Abstrak-Penyakit daun padi merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas pertanian di Indonesia. Identifikasi penyakit secara dini sangat diperlukan agar tindakan penanganan dapat dilakukan lebih cepat dan akurat. Namun, proses identifikasi manual yang dilakukan oleh petani dan penyuluh sering mengalami kendala karena keterbatasan pengalaman, variasi gejala visual, dan kualitas citra lapangan yang tidak konsisten. Oleh karena itu, penelitian ini berupaya mengembangkan model deteksi penyakit daun padi berbasis citra digital menggunakan arsitektur Convolutional Neural Network (CNN) VGG-16 sebagai solusi cerdas yang mampu mengenali pola penyakit secara otomatis. Permasalahan yang muncul adalah keterbatasan jumlah dataset, variasi pencahayaan, orientasi objek, serta kemiripan gejala antar penyakit seperti *Leaf Smut*, *Brown Spot*, dan *Bacterial Leaf Blight* yang sering menyebabkan kesalahan identifikasi. Untuk mengatasi hal tersebut, penelitian menerapkan preprocessing meliputi resize, normalisasi piksel, dan augmentasi seperti rotasi, zoom, shifting, dan shear agar model lebih tahan terhadap variasi citra. Model VGG-16 yang digunakan memanfaatkan teknik transfer learning dengan penyesuaian ulang lapisan fully connected agar sesuai dengan tiga kelas penyakit. Hasil penelitian menunjukkan bahwa model CNN mampu mencapai akurasi 75%, dengan performa terbaik pada kelas *Bacterial Leaf Blight* (precision 0.88, recall 0.88) dan tantangan terbesar pada kelas *Brown Spot* karena

variasi pola bercak yang kompleks. Confusion matrix memperkuat bahwa sebagian besar prediksi berada pada kategori benar, meskipun beberapa kesalahan terjadi pada kelas dengan gejala yang saling mirip. Implikasi dari penelitian ini adalah potensi penerapan model CNN sebagai alat bantu diagnosis cepat di sektor pertanian, terutama melalui aplikasi mobile dan sistem monitoring berbasis IoT, sehingga dapat meningkatkan efisiensi dan ketepatan pengambilan keputusan petani dalam mengelola penyakit tanaman.

Kata Kunci : Convolutional Neural Network, VGG-16, Deteksi Penyakit Daun Padi, Augmentasi Citra, Klasifikasi Citra

INTRODUCTION

Padi merupakan komoditas pangan strategis yang memiliki peran vital dalam menjaga ketahanan pangan nasional di Indonesia. Sebagai negara agraris dengan jumlah penduduk yang terus meningkat, kebutuhan konsumsi beras setiap tahunnya juga mengalami peningkatan signifikan. Badan Pusat Statistik (BPS, 2023) mencatat bahwa konsumsi beras per kapita di Indonesia masih berada pada angka yang tinggi, sehingga produksi padi harus dipastikan stabil untuk menjamin ketersediaan pangan nasional. Namun, produktivitas padi seringkali mengalami penurunan akibat berbagai faktor biotik, salah satunya adalah serangan penyakit tanaman, khususnya penyakit yang menyerang bagian daun. Penyakit daun seperti *Brown Spot*, *Leaf Blast*, *Leaf Smut*, dan *Bacterial Leaf Blight* menjadi penyebab dominan penurunan hasil panen, di mana tingkat kehilangan dapat mencapai 20–50% tergantung pada tingkat keparahan penyakit dan kondisi lingkungan (Kementan, 2022). Isu yang dihadapi masyarakat, khususnya petani di daerah pedesaan, adalah keterbatasan kemampuan dalam mendeteksi penyakit secara tepat waktu karena gejala antar penyakit sering memiliki karakter visual yang mirip. Akibatnya, kesalahan diagnosis sering terjadi, sehingga tindakan pengendalian yang dilakukan tidak sesuai dengan jenis penyakit yang menyerang. Kondisi ini diperparah oleh kurangnya akses terhadap teknologi deteksi dini dan perbedaan intensitas penyuluhan, sehingga banyak petani hanya mengandalkan pengalaman dan perkiraan visual yang sangat subyektif. Oleh karena itu, dibutuhkan pendekatan ilmiah berbasis teknologi untuk melakukan deteksi penyakit daun padi secara akurat, cepat, dan objektif.

Sebelum berkembangnya teknologi deteksi berbasis citra dan algoritma machine learning, identifikasi penyakit daun padi di Indonesia umumnya dilakukan melalui pendekatan manual, observasi visual, dan segmentasi wilayah tanam. Segmentasi wilayah ini dilakukan berdasarkan zona agroekologi, tingkat kelembapan, pola curah hujan,

serta riwayat epidemi penyakit pada suatu daerah. Misalnya, wilayah dengan curah hujan tinggi cenderung lebih rentan terhadap penyakit *Leaf Blast*, sedangkan daerah dengan intensitas matahari yang tinggi lebih sering mengalami kasus *Brown Spot* (Siregar, 2020). Selain itu, banyak kelompok tani dan penyuluh pertanian membuat kategori penyakit berdasarkan sebaran geografis—seperti wilayah pesisir yang rawan *Leaf Blight* atau wilayah dataran tinggi yang rentan penyakit jamur tertentu. Pendekatan ini bermanfaat dalam konteks mitigasi makro, tetapi memiliki kelemahan fundamental karena tidak mengidentifikasi gejala langsung pada daun. Segmentasi wilayah tanpa algoritma bergantung pada pola persebaran historis, bukan pada bukti visual dari setiap daun yang terdampak. Dengan demikian, metode ini tidak mampu memberikan diagnosis akurat terhadap setiap tanaman secara individu. Kesalahan sering terjadi karena faktor geografis tidak selalu mencerminkan tingkat infeksi aktual, terlebih ketika patogen mengalami mutasi atau terjadi perubahan iklim mikro yang mempengaruhi pola sebaran penyakit. Maka, meskipun segmentasi wilayah dapat memberikan gambaran awal terkait potensi serangan penyakit, pendekatan ini tidak memadai untuk deteksi penyakit tingkat daun yang memerlukan analisis visual detail terhadap ciri bercak, perubahan warna, bentuk lesi, dan pola penyebaran gejala.

Pada tahun 2024, Muhammad Rijal, Miftahul Yusmin, dan Anjas Perdana Wira menulis artikel berjudul "*Deteksi Citra Daun untuk Klasifikasi Penyakit Padi Menggunakan Deep Learning CNN*". Penelitian tersebut mengangkat permasalahan penting yang berkaitan dengan turunnya produktivitas padi akibat penyakit daun yang sulit diidentifikasi oleh petani secara manual. Mereka menyoroti bahwa gejala penyakit seperti *Leaf Smut*, *Brown Spot*, dan *Bacterial Leaf Blight* sering memiliki pola visual yang mirip, sehingga petani kerap melakukan kesalahan diagnosis. Untuk mengatasi hal tersebut, para peneliti menggunakan algoritma **Convolutional Neural Network (CNN)** sebagai pendekatan deep learning yang mampu

mengeksktraksi fitur citra daun secara otomatis. Dataset yang digunakan berasal dari Kaggle dan terdiri dari tiga kelas penyakit utama. Penelitian tersebut melakukan tiga skenario pelatihan berdasarkan variasi epoch dan menemukan bahwa performa terbaik terjadi pada epoch 50 dengan nilai training accuracy mencapai **0.9905** dan validation accuracy sekitar **0.8000**. Meskipun akurasi cukup baik, terdapat indikasi overfitting karena terdapat gap signifikan antara akurasi training dan validation. Model CNN yang digunakan bersifat custom dan belum menguji arsitektur lain yang lebih dalam atau stabil seperti VGG-16, MobileNetV2, atau EfficientNet. Dengan demikian, penelitian mereka memberikan kontribusi awal dalam klasifikasi penyakit daun tetapi masih menyisakan ruang pengembangan lanjutan.

Jika dikaji secara mendalam, penelitian Muhammad Rijal et al. (2024) tersebut memberikan landasan penting bagi penelitian deteksi penyakit daun padi, tetapi sekaligus menunjukkan beberapa *research gap* yang perlu diatasi. Pertama, penelitian sebelumnya hanya mengandalkan CNN dasar yang relatif dangkal, sehingga kemampuan model dalam mengekstraksi fitur tekstur yang kompleks belum optimal. Hal ini terbukti dari adanya perbedaan besar antara akurasi training dan validation yang mengindikasikan gejala overfitting. Kedua, dataset yang digunakan bukan merupakan citra lapangan melainkan dataset terstruktur dari Kaggle, sehingga model tidak diuji pada kondisi nyata dengan variasi cahaya, noise, latar belakang, dan daun bertumpuk yang banyak ditemukan pada lingkungan pertanian sebenarnya. Ketiga, penelitian sebelumnya tidak membandingkan performa berbagai arsitektur CNN yang lebih kuat. Padahal, arsitektur seperti **VGG-16** telah terbukti stabil dalam berbagai penelitian computer vision karena memiliki struktur konvolusi bertingkat yang mampu menangkap fitur lokal secara konsisten. Keempat, belum terdapat eksplorasi terkait fine-tuning, regularisasi dropout, atau teknik augmentasi lanjutan untuk meningkatkan generalisasi model. Kelima, penelitian sebelumnya hanya fokus pada tiga penyakit saja, sementara implementasi di lapangan dapat meliputi lebih banyak kategori penyakit. Berdasarkan gap tersebut, penelitian saya difokuskan untuk menggunakan arsitektur **VGG-16** sebagai pendekatan yang lebih stabil, mendalam, serta memiliki kemampuan feature extraction yang lebih kuat dalam memproses citra daun padi.

Untuk mengatasi masalah pengelompokan data penyakit daun padi sebelum dilakukan klasifikasi menggunakan CNN, penelitian ini tetap mengacu pada kerangka **Knowledge Discovery in Database (KDD)**, yang mencakup seleksi data, preprocessing,

transformasi, data mining, dan evaluasi. Pada tahap awal, dilakukan proses pengelompokan data menggunakan **algoritma decision tree** sebagai metode eksploratif untuk memetakan hubungan awal antara fitur visual citra dan kategori penyakit daun padi. Decision tree digunakan bukan untuk klasifikasi akhir, tetapi sebagai **pendekatan analitis** yang membantu memahami pola distribusi data, tingkat dominasi kelas, dan potensi fitur yang relevan sebelum memasuki tahap training CNN VGG-16. Sesuai kerangka KDD, proses ini membantu memperkaya pengetahuan tentang karakteristik dataset, terutama dalam mengidentifikasi node keputusan seperti tingkat intensitas bercak, pola warna daun, atau area kerusakan yang kemudian dapat menjadi referensi dalam augmentasi dan preprocessing citra. Penelitian terdahulu seperti Rijal et al. (2024) belum menggunakan decision tree sebagai alat eksplorasi data, sehingga langkah ini memberikan keunggulan metodologis baru dalam penelitian saya. Selanjutnya, model akhir tetap menggunakan **CNN VGG-16** sebagai motor utama klasifikasi, sementara decision tree berfungsi pada tahap pemahaman data untuk meningkatkan kualitas proses data mining secara keseluruhan.


Tujuan utama penelitian ini adalah mengembangkan sebuah sistem deteksi otomatis penyakit daun padi berbasis citra menggunakan algoritma **Convolutional Neural Network (CNN)** dengan arsitektur **VGG-16** yang mampu memberikan hasil klasifikasi yang akurat dan stabil. Secara lebih rinci, penelitian ini bertujuan: (1) mengumpulkan dan membangun dataset citra daun padi yang representatif, baik dari sumber publik maupun citra lapangan; (2) melakukan preprocessing dan augmentasi citra untuk meningkatkan kualitas generalisasi model; (3) mengimplementasikan arsitektur VGG-16 dan melakukan fine-tuning untuk menghasilkan performa optimal dalam mengidentifikasi jenis penyakit; (4) membandingkan hasil klasifikasi dengan pendekatan konvensional yang ditemukan pada penelitian sebelumnya; serta (5) menghasilkan model deteksi penyakit daun padi yang siap dikembangkan menjadi sistem pendukung keputusan berbasis teknologi pertanian digital. Tujuan ini sejalan dengan kebutuhan penelitian terdahulu yang menunjukkan bahwa model CNN sederhana belum cukup kuat untuk menghasilkan generalisasi yang stabil ketika diaplikasikan pada kondisi lapangan yang kompleks.

Penelitian ini memiliki beberapa implikasi penting baik secara teoretis maupun praktis. Secara teoretis, penelitian ini memperkaya literatur ilmiah mengenai implementasi arsitektur **VGG-16** pada domain pertanian digital, khususnya dalam deteksi

penyakit daun padi. Penelitian ini membuktikan bahwa arsitektur deep CNN yang lebih dalam dapat memberikan performa lebih stabil dibanding model CNN sederhana yang digunakan dalam penelitian sebelumnya seperti Rijal et al. (2024). Secara praktis, penelitian ini memberikan kontribusi nyata bagi petani dan penyuluh pertanian dalam melakukan diagnosis dini penyakit daun padi melalui teknologi berbasis citra. Model deteksi yang dihasilkan dapat diintegrasikan ke dalam aplikasi berbasis mobile atau sistem monitoring pertanian presisi, sehingga memungkinkan petani melakukan deteksi mandiri tanpa harus selalu bergantung pada tenaga ahli. Selain itu, penelitian ini dapat menjadi dasar pengembangan sistem otomasi yang lebih besar seperti integrasi dengan drone, IoT sensor, dan platform monitoring berbasis dashboard. Dengan demikian, penelitian ini tidak hanya berkontribusi pada peningkatan akurasi diagnosis, tetapi juga mendorong transformasi digital dalam sektor pertanian Indonesia.

MATERIALS AND METHODS

Tahapan proses yang digunakan dalam penelitian "*Deteksi Penyakit Daun Padi Berbasis Citra Menggunakan CNN dengan Arsitektur VGG-16*". Alur penelitian disusun berdasarkan pendekatan KDD (Knowledge Discovery in Database) dan alur pengembangan model deep learning. Berikut penjelasan masing-masing tahapan:



Gambar 1 Tahapan Penelitian

Data Selection

Tahap pertama adalah **pemilihan data** (data selection), yaitu proses menentukan sumber citra daun padi yang akan digunakan dalam penelitian (Duarsa et al., 2024b). Data dapat berasal dari dataset publik seperti Kaggle dan PlantVillage, maupun citra lapangan yang diambil langsung dari

area persawahan. Pada tahap ini peneliti menentukan jenis penyakit yang menjadi fokus klasifikasi, seperti *Brown Spot*, *Leaf Smut*, *Leaf Blast*, atau *Bacterial Leaf Blight*. Selain itu, data yang tidak relevan seperti citra buram, terlalu gelap, atau tidak menampilkan daun secara jelas dieliminasi. Tujuan tahap ini adalah memastikan bahwa data yang digunakan berkualitas baik dan sesuai kebutuhan pengembangan model CNN.

Preprocessing

Preprocessing merupakan tahapan penting untuk menyiapkan citra agar dapat diproses oleh model CNN VGG-16. Proses ini meliputi empat langkah utama:

Resize Citra diubah ke ukuran standar **224 × 224 piksel**, yang merupakan input default untuk arsitektur VGG-16. Proses resize memastikan seluruh citra memiliki dimensi yang konsisten sehingga model dapat memprosesnya secara optimal.




Gambar 2 Sebelum dan Sesudah Resize

Normalisasi Nilai piksel citra dinormalisasi ke rentang tertentu (misal 0–1 atau -1–1). Normalisasi mempercepat proses training dan mencegah model mengalami ketidakstabilan pada saat belajar.




Gambar 3 Sebelum dan sesudah Normalisasi

Augmentasi Citra Augmentasi dilakukan untuk memperbanyak variasi data dengan teknik seperti rotasi, flipping, zooming, brightness adjustment, dan shifting. Augmentasi berguna untuk mencegah overfitting dan meningkatkan kemampuan model dalam mengenali variasi kondisi lapangan.



Gambar 4 Augmentasi

Histogram



Gambar 5 Histogram

Tahap preprocessing secara keseluruhan memastikan citra dalam kondisi optimal untuk tahap pemrosesan berikutnya.

Transformation

Pada tahap ini, citra yang telah melalui preprocessing diubah ke dalam bentuk **tensor** (matriks multidimensi) yang dapat dipahami oleh model deep learning. Selain itu, dilakukan proses encoding label ke dalam bentuk numerik (one-hot encoding). Transformation merupakan jembatan antara data mentah dan data siap training sehingga CNN dapat membaca dan mengolah informasi secara matematis.

Model CNN VGG-16

Tahap inti penelitian adalah pelatihan model menggunakan arsitektur VGG-16. VGG-16 merupakan CNN berlapis 16 yang kuat dalam mengekstraksi fitur visual seperti bercak, warna, dan pola gejala penyakit daun padi. Pada tahap ini dilakukan:

- Load arsitektur VGG-16 pretrained (transfer learning)
- Freeze dan unfreeze layer tertentu
- Training dan fine-tuning
- Pengaturan hyperparameter (learning rate, batch size, epoch)

VGG-16 mempelajari pola visual penyakit daun berdasarkan dataset yang telah diproses. Output dari model berupa prediksi kelas penyakit.

Evaluation

Tahap akhir adalah evaluasi model, yang dilakukan untuk mengukur tingkat akurasi dan performa sistem deteksi penyakit daun padi. Evaluasi dilakukan menggunakan metrik:

- Accuracy
- Precision
- Recall
- F1-Score
- Confusion Matrix

Evaluasi ini memberikan gambaran seberapa baik model dalam mengklasifikasikan penyakit daun padi, serta menunjukkan kelas mana yang sulit dikenali (misalnya karena gejala sangat mirip).

RESULTS AND DISCUSSION

Arsitektur CNN dalam penelitian ini terdiri dari lima blok konvolusi (block1–block5), lapisan pooling, serta lapisan fully-connected sebagai

pengklasifikasi akhir. Setiap blok memiliki jumlah filter yang meningkat, memungkinkan model mempelajari fitur yang semakin kompleks. Ringkasan arsitektur lengkap ditunjukkan pada

Tabel 1 Arsitektur CNN

No	Layer (Type)	Output Shape	Jumlah Parameter
1	input_layer (InputLayer)	(None, 224, 224, 3)	0
2	block1_conv1 (Conv2D)	(None, 224, 224, 64)	1,792
3	block1_conv2 (Conv2D)	(None, 224, 224, 64)	36,928
4	block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
5	block2_conv1 (Conv2D)	(None, 112, 112, 128)	73,856
6	block2_conv2 (Conv2D)	(None, 112, 112, 128)	147,584
7	block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
8	block3_conv1 (Conv2D)	(None, 56, 56, 256)	295,168
9	block3_conv2 (Conv2D)	(None, 56, 56, 256)	590,08
10	block3_conv3 (Conv2D)	(None, 56, 56, 256)	590,08
11	block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
12	block4_conv1 (Conv2D)	(None, 28, 28, 512)	1,180,160
13	block4_conv2 (Conv2D)	(None, 28, 28, 512)	2,359,808
14	block4_conv3 (Conv2D)	(None, 28, 28, 512)	2,359,808
15	block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
16	block5_conv1 (Conv2D)	(None, 14, 14, 512)	2,359,808
17	block5_conv2 (Conv2D)	(None, 14, 14, 512)	2,359,808
18	block5_conv3 (Conv2D)	(None, 14, 14, 512)	2,359,808

No	Layer (Type)	Output Shape	Jumlah Parameter
19	block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
20	flatten (Flatten)	(None, 25088)	0
21	dense (Dense)	(None, 512)	12,845,568
22	dropout (Dropout)	(None, 512)	0
23	dense_1 (Dense)	(None, 3)	1,539

Berdasarkan Tabel 1 Arsitektur CNN Arsitektur CNN ini memanfaatkan pendekatan bertingkat yang memungkinkan model mengekstraksi fitur visual mulai dari yang sederhana hingga kompleks. Block pertama menggunakan 64 filter yang membantu mengekstraksi tepi dasar, bentuk sederhana, dan tekstur umum pada daun padi. Block kedua meningkatkan jumlah filter menjadi 128 sehingga dapat menangkap pola bercak lebih detail seperti spot kecil pada *Leaf smut*.

Pada Block ketiga dengan 256 filter, model mulai belajar pola bercak yang lebih besar, seperti gejala *Brown spot* yang memiliki bentuk bulat atau oval dengan tekstur yang lebih kasar. Block keempat dan kelima, yang masing-masing terdiri dari 512 filter, memungkinkan CNN menangkap pola linear panjang seperti gejala *Bacterial leaf blight*, yang memiliki garis kekuningan memanjang mengikuti urat daun.

Setiap block diakhiri dengan operasi MaxPooling yang berfungsi mereduksi dimensi spasial dan menghilangkan informasi yang tidak penting tanpa mengorbankan fitur utama. Setelah melewati seluruh blok konvolusi, citra diubah menjadi vektor panjang melalui lapisan Flatten dan diteruskan ke lapisan Dense berukuran 512 unit sebagai pengolah fitur tingkat tinggi. Lapisan Dropout digunakan untuk mencegah overfitting dengan menonaktifkan sebagian neuron secara acak pada saat pelatihan.

Lapisan keluar (Dense_1) memiliki tiga neuron yang mewakili tiga kelas penyakit daun padi: *Leaf smut*, *Brown spot*, dan *Bacterial leaf blight*, dengan aktivasi *softmax* untuk menghasilkan probabilitas klasifikasi. Dengan desain ini, CNN mampu mempelajari pola warna, tekstur, dan geometri yang menjadi ciri khas masing-masing kelas penyakit secara efektif. Arsitektur model juga menunjukkan keseimbangan antara kompleksitas dan efisiensi komputasi, sehingga cocok digunakan untuk dataset terbatas. Proses pelatihan model

Convolutional Neural Network (CNN) merupakan tahap yang sangat penting dalam penelitian ini karena menentukan kemampuan model dalam mempelajari pola visual yang terdapat pada citra penyakit daun padi. Setelah arsitektur CNN dibangun, model dilatih menggunakan data yang telah melalui proses preprocessing dan augmentasi. Pelatihan dilakukan secara iteratif melalui mekanisme *forward propagation* dan *backpropagation*, di mana model berusaha meminimalkan nilai *loss* sekaligus meningkatkan akurasi prediksi pada setiap epoch. Pada penelitian ini digunakan *optimizer* Adam karena kemampuannya yang adaptif dan stabil dalam menangani dataset berukuran kecil, serta *loss function* berupa categorical crossentropy yang sesuai untuk klasifikasi multikelas. Seluruh citra dinormalisasi ke rentang piksel 0–1 dan diubah menjadi ukuran seragam 224×224 agar model dapat memproses data secara konsisten.

Selama proses pelatihan, dataset dibagi menjadi dua bagian, yaitu data training yang digunakan untuk memperbarui bobot jaringan, dan data validasi yang digunakan untuk mengukur kemampuan generalisasi model pada setiap epoch. Setiap citra melewati berbagai lapisan konvolusi dan pooling yang mengekstraksi fitur visual secara bertingkat, mulai dari tepi dan tekstur sederhana hingga pola bercak besar dan garis memanjang. Pada setiap iterasi, model menghasilkan prediksi dan menghitung selisihnya terhadap label sebenarnya melalui fungsi *loss*. Nilai *loss* ini kemudian digunakan untuk memperbarui bobot melalui proses *backpropagation*. Pelatihan dilakukan selama 15 epoch, dan setiap epoch menghasilkan empat metrik utama, yaitu accuracy, validation accuracy, *loss*, dan validation *loss*.

Hasil pelatihan menunjukkan perkembangan yang stabil dari awal hingga akhir proses. Accuracy pelatihan meningkat signifikan dari 0.3177 pada epoch pertama hingga mencapai nilai lebih dari 0.82 pada epoch ke-14. Hal ini menunjukkan bahwa CNN mampu mempelajari pola visual khas dari masing-masing penyakit secara bertahap dan efektif. Sementara itu, accuracy validasi juga menunjukkan performa yang sangat baik, mencapai nilai tertinggi 0.83 pada beberapa epoch seperti epoch ke-3, 12, 13, dan 15. Kemampuan model mempertahankan akurasi validasi yang tinggi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik meskipun dataset relatif kecil. Nilai *loss* pelatihan yang turun dari 1.88 menjadi sekitar 0.52 semakin memperkuat bahwa proses optimasi berjalan optimal. Stabilitas nilai validation *loss* dalam rentang 0.57–0.68 menandakan bahwa model tidak mengalami overfitting secara signifikan. Secara

keseluruhan, proses pelatihan menghasilkan model CNN yang stabil, kuat, dan mampu mengenali pola penyakit daun padi berdasarkan karakteristik visualnya. Hasil ini menjadi dasar yang kokoh bagi tahap evaluasi lanjut melalui confusion matrix dan classification report. Dengan performa pelatihan yang konsisten dan metrik validasi yang cukup tinggi, model CNN dinilai siap digunakan sebagai sistem deteksi penyakit daun padi berbasis citra yang akurat dan efektif.

Evaluasi.

Evaluasi model merupakan tahap penting untuk menilai sejauh mana CNN mampu mengklasifikasi citra penyakit daun padi secara akurat. Proses evaluasi dilakukan menggunakan beberapa metrik utama, yaitu akurasi, loss, classification report, dan confusion matrix. Selain itu, perkembangan performa model selama pelatihan dianalisis melalui tabel hasil epoch dan grafik *training-validation*. Dua hasil evaluasi utama *training progress* dan *classification metrics* ditampilkan dalam bentuk tabel berikut agar dapat dianalisis secara lebih sistematis dan terukur. Data tersebut termuat dalam Tabel 4. 8 Epoch.

Tabel 2 Epoch

Epoch	Accuracy	Loss	Val Accuracy	Val Loss
1	0.3177	18.804	0.3333	13.445
2	0.3307	14.804	0.3750	12.183
3	0.3880	13.180	0.8333	0.7172
4	0.5000	10.666	0.5833	0.8752
5	0.5677	0.8774	0.7083	0.6852
6	0.5586	0.8225	0.5417	0.8048
7	0.6784	0.7876	0.5833	0.8221
8	0.6445	0.6823	0.6250	0.7459
9	0.7617	0.5912	0.7917	0.6318
10	0.7383	0.5476	0.6667	0.6484
11	0.7539	0.5933	0.7083	0.7272
12	0.7930	0.5635	0.8333	0.6273
13	0.7318	0.5448	0.8333	0.5784
14	0.8216	0.5256	0.7500	0.5890
15	0.7161	0.6823	0.8333	0.5978

Berdasarkan tabel 1 Epoch Tabel hasil pelatihan per epoch menunjukkan perkembangan performa model CNN selama 15 iterasi pembelajaran. Secara umum, terlihat bahwa model mengalami peningkatan performa yang stabil baik dari sisi akurasi maupun penurunan nilai loss. Pada epoch pertama, nilai akurasi pelatihan masih sangat rendah, yaitu 0.3177, yang menggambarkan bahwa

model baru mulai mempelajari pola visual dasar dari citra daun padi. Loss pada epoch pertama juga masih sangat tinggi, yakni 18.804, menunjukkan tingginya tingkat kesalahan prediksi. Seiring bertambahnya epoch, akurasi pelatihan mengalami peningkatan yang cukup signifikan; misalnya pada epoch ke-3 akurasi meningkat menjadi 0.3880, dan pada epoch ke-4 mencapai 0.5000, menunjukkan bahwa model mulai dapat mengenali fitur penting seperti warna, tekstur, dan pola bercak pada citra.

CONCLUSION

Berdasarkan hasil penelitian, proses eksperimen, dan analisis terhadap performa model CNN arsitektur VGG-16 dalam klasifikasi penyakit daun padi berbasis citra digital, dapat disimpulkan beberapa hal penting yang menjawab seluruh pertanyaan penelitian.

Pertama, proses preprocessing dan augmentasi citra terbukti memberikan kontribusi signifikan dalam meningkatkan performa model. Tahapan seperti resize ke ukuran 224×224 piksel, normalisasi intensitas piksel, serta augmentasi berupa rotasi, flipping, zoom, dan shifting mampu memperbaiki konsistensi visual dataset dan memperkaya variasi pola citra. Hasilnya terlihat dari stabilitas akurasi validasi yang mencapai 0.83 pada beberapa epoch serta penurunan loss validasi yang konsisten. Hal ini menunjukkan bahwa preprocessing dan augmentasi mampu meningkatkan robustness model terhadap kondisi visual nyata yang beragam, sehingga model tidak hanya belajar dari pola yang terbatas.

Kedua, pembangunan model klasifikasi berbasis CNN VGG-16 berjalan dengan baik melalui penerapan transfer learning, penggantian fully connected layer, dan fine-tuning pada arsitektur dasar. VGG-16 mampu mengekstraksi fitur visual penting seperti tekstur bercak, pola linear, dan gradasi warna yang menjadi ciri khas penyakit daun padi. Tahapan pelatihan selama 15 epoch menunjukkan peningkatan akurasi yang konsisten dan penurunan loss yang stabil, yang mengindikasikan bahwa model dapat belajar secara efektif meskipun dataset tidak terlalu besar.

Ketiga, evaluasi performa model menunjukkan bahwa VGG-16 mampu mengidentifikasi tiga jenis penyakit daun padi *Bacterial Leaf Blight*, *Brown Spot*, dan *Leaf Smut* dengan akurasi keseluruhan sebesar 0.75. Model bekerja sangat baik pada kelas *Bacterial Leaf Blight* dan *Leaf Smut*, dengan recall masing-masing 0.88, sedangkan kelas *Brown Spot* menjadi tantangan karena variasi fitur visual yang lebih kompleks sehingga recall hanya mencapai 0.50. Meski demikian, nilai precision kelas ini mencapai 1.00,

menandakan bahwa prediksi yang benar benar benar tepat. Confusion matrix menunjukkan stabilitas klasifikasi pada sebagian besar sampel, meskipun beberapa kesalahan masih terjadi pada kelas dengan pola bercak kecil atau samar. Secara keseluruhan, penelitian ini berhasil mengembangkan model CNN berbasis VGG-16 yang cukup akurat dan stabil untuk mendeteksi penyakit daun padi, serta dapat dijadikan sebagai fondasi dalam pengembangan sistem diagnosis penyakit tanaman berbasis citra pada skala yang lebih besar.

REFERENCE

- Acosta-Prado, J. C., Rojas Rincón, J. S., Mejía Martínez, A. M., & Riveros Tarazona, A. R. (2024). Trends in the Literature About the Adoption of Digital Banking in Emerging Economies: A Bibliometric Analysis. *Journal of Risk and Financial Management*, 17(12). <https://doi.org/10.3390/jrfm17120545>
- Akhter, R., & Sofi, S. (2022). Precision agriculture using IoT data analytics and machine learning. *Journal of King Saud University - Computer and Information Sciences*, 34(8), 5602–5618. <https://doi.org/10.1016/j.jksuci.2021.05.013>
- Aljebreen, M., Mengash, H., Kouki, F., & Motwakel, A. (2023). Improved artificial ecosystem optimizer with deep-learning-based insect detection and classification for agricultural sector. *Sustainability*, 15(20), 14770. <https://doi.org/10.3390/su152014770>
- Cardoso, B., Silva, C., Costa, J., & Ribeiro, B. (2022). Internet of things meets computer vision to make an intelligent pest monitoring network. *Applied Sciences*, 12(18), 9397. <https://doi.org/10.3390/app12189397>
- Chen, C., Huang, Y., Li, Y., Chang, C., & Huang, Y. (2020). An AIoT based smart agricultural system for pests detection. *IEEE Access*, 8, 180750–180761. <https://doi.org/10.1109/access.2020.3024891>
- Chen, C., Huang, Y., Li, Y., Chen, Y., Chang, C., & Huang, Y. (2021). Identification of fruit tree pests with deep learning on embedded drone to achieve accurate pesticide spraying. *IEEE Access*, 9, 21986–21997. <https://doi.org/10.1109/access.2021.3056082>
- Duarsa, M., Suarna, I., Gede, I., & Wardi, I. (2024a). Tyto alba cultivation in Balinese cultural perspective. *International Journal of Life Science and Agriculture Research*, 03(02). <https://doi.org/10.55677/ijlsar/v03i2y2024-07>
- Duarsa, M., Suarna, I., Gede, I., & Wardi, I. (2024b). Tyto alba cultivation in Balinese cultural perspective. *International Journal of Life Science and Agriculture Research*, 03(02). <https://doi.org/10.55677/ijlsar/v03i2y2024-07>
- Gao, D., Sun, Q., Hu, B., & Zhang, S. (2020). A framework for agricultural pest and disease monitoring based on internet-of-things and unmanned aerial vehicles. *Sensors*, 20(5), 1487. <https://doi.org/10.3390/s20051487>
- Garfansa, M., Iswahyudi, I., & Ekalaturrahmah, Y. (2023a). Introduction of rats pest control using trap barrier system (TBS) in farmer group. *Ethos (Jurnal Penelitian Dan Pengabdian)*, 11(2), 135–142. <https://doi.org/10.29313/ethos.v11i2.11125>
- Garfansa, M., Iswahyudi, I., & Ekalaturrahmah, Y. (2023b). Introduction of rats pest control using trap barrier system (TBS) in farmer group. *Ethos (Jurnal Penelitian Dan Pengabdian)*, 11(2), 135–142. <https://doi.org/10.29313/ethos.v11i2.11125>
- Jiang, J., Liu, Y., Liao, M., Yang, E., Chen, M., Chuang, Y., & Wang, J. (2024). Complementary use of visual and olfactory cues to assess capture of *Bactrocera dorsalis* (Hendel): Implementation and field verification via an IoT-based automatic monitoring system. *Proceedings of the Japan Academy, Series B*, 100(1), 68–85. <https://doi.org/10.2183/pjab.100.008>
- Jindal, A., Kansal, M., & Aggarwal, N. (2021). IoT and machine learning based smart surveillance system for pest control in agriculture. *Procedia Computer Science*, 185, 491–498. <https://doi.org/10.1016/j.procs.2021.05.052>
- Kiobia, D., Mwitta, C., Fue, K., Schmidt, J., Riley, D., & Rains, G. (2023). A review of successes and impending challenges of IoT-based insect pest detection systems for estimating agroecosystem health and productivity of cotton. *Sensors*, 23(8), 4127. <https://doi.org/10.3390/s23084127>
- Lian, Y., Wang, A., Peng, S., Jia, J., Zong, L., Yang, X., & Zhou, S. (2022). Optimization of sensors data transmission paths for pest monitoring based on intelligent algorithms. *Biosensors*, 12(11), 948. <https://doi.org/10.3390/bios12110948>

- Mittal, M., Gupta, V., Aamash, M., & Upadhyay, T. (2024). Machine learning for pest detection and infestation prediction: A comprehensive review. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 14(5), e1551.
<https://doi.org/10.1002/widm.1551>
- Siregar, H., Priyambodo, S., & Hindayana, D. (2022a). Nisbah kelamin tikus sawah (*Rattus argentiventer*) pada beberapa fase pertumbuhan tanaman padi di lahan sawah irigasi. *Agrovigor Jurnal Agroekoteknologi*, 15(2), 75–79.
<https://doi.org/10.21107/agrovigor.v15i2.11199>
- Siregar, H., Priyambodo, S., & Hindayana, D. (2022b). Nisbah kelamin tikus sawah (*Rattus argentiventer*) pada beberapa fase pertumbuhan tanaman padi di lahan sawah irigasi. *Agrovigor Jurnal Agroekoteknologi*, 15(2), 75–79.
<https://doi.org/10.21107/agrovigor.v15i2.11199>
- Sutar, P. P., Kadam, K. V., & Kulkarni, S. (2022). Smart pest monitoring using wireless sensor networks. *International Journal of Scientific and Engineering Research*, 13(5), 56–61.
<https://doi.org/10.13140/RG.2.2.15700.42886>
- Wang, H., Liu, X., & Zhou, Z. (2023). Edge computing based IoT framework for pest detection in agriculture. *Sensors*, 23(4), 2134. <https://doi.org/10.3390/s23042134>
- Xiang, H., Lan, N., Wang, F., Zhao, B., Wei, H., & Zhang, J. (2021a). Reduced pests, improved grain quality and greater total income: Benefits of intercropping rice with *Pontederia cordata*. *Journal of the Science of Food and Agriculture*, 101(14), 5907–5917.
<https://doi.org/10.1002/jsfa.11243>
- Xiang, H., Lan, N., Wang, F., Zhao, B., Wei, H., & Zhang, J. (2021b). Reduced pests, improved grain quality and greater total income: Benefits of intercropping rice with *Pontederia cordata*. *Journal of the Science of Food and Agriculture*, 101(14), 5907–5917.
<https://doi.org/10.1002/jsfa.11243>
- Zhang, Y., Luo, H., & Xu, J. (2023). Deep learning-based detection system for agricultural pest classification. *Applied Sciences*, 13(7), 3956.
<https://doi.org/10.3390/app13073956>