

**Identifikasi Penyakit Tanaman Padi Disebabkan Oleh Bakteri dan Jamur
Menggunakan Metode Convolutional Neural Network (CNN)**
***Identification of Rice Plant Diseases Caused by Bacteria and Fungi Using Convolutional
Neural Network (CNN) Method***

Ridho Ananta Bahariawan¹⁾, Agung Nilogiri²⁾, Taufiq Timur³⁾

¹⁾Mahasiswa Program Studi Teknik Informatika, Universitas Muhammadiyah Jember

email: ridhoanantab@gmail.com

²⁾Dosen Teknik Informatika, Universitas Muhammadiyah Jember

email: agungnilogiri@unmuhjember.ac.id

³⁾Dosen Teknik Informatika, Universitas Muhammadiyah Jember

email: taufiqtimur@unmuhjember.ac.id

Abstrak

Beras merupakan salah satu makanan utama yang banyak dikonsumsi di Indonesia, akan tetapi bidang produksi beras menghadapi tantangan yaitu serangan penyakit pada tanaman padi. Penyakit seperti Bacterial Leaf Blight dan Brown Spot dapat menyebabkan kehilangan hasil panen yang signifikan. Oleh karena itu, diperlukan sistem untuk mendeteksi dan mengklasifikasikan penyakit pada tanaman padi secara otomatis. Penelitian ini merupakan penelitian kuantitatif yang mengembangkan model klasifikasi penyakit padi menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur MobileNetV3 untuk perangkat mobile. Metode penelitian yang digunakan meliputi pengumpulan data dari dataset publik Kaggle, tahap pra-pemrosesan citra dengan teknik foreground extraction, perancangan dan pelatihan model CNN berbasis MobileNetV3, serta evaluasi model menggunakan k-fold cross-validation ($k = 10$) untuk memastikan keandalan hasil. Eksperimen dilakukan dengan menerapkan teknik k-fold tersebut, dan hasil terbaik diperoleh pada nilai $k = 1$ dengan akurasi mencapai 98% dan nilai loss sebesar 0,02, menunjukkan bahwa model yang dikembangkan memiliki performa yang sangat baik dalam mengklasifikasi penyakit pada tanaman padi.

Kata Kunci: Bakteri; Convolutional Neural Network (CNN); Identifikasi; Jamur; Penyakit Tanaman Padi.

Abstract

Rice is one of the main staple foods widely consumed in Indonesia; however, rice production faces challenges such as disease attacks on rice plants. Diseases like Bacterial Leaf Blight and Brown Spot can cause significant crop losses. Therefore, a system is needed to automatically detect and classify diseases in rice plants. This study is a quantitative research that develops a rice disease classification model using the Convolutional Neural Network (CNN) method with the MobileNetV3 architecture for mobile devices. The research method includes data collection from a public Kaggle dataset, image pre-processing using foreground extraction techniques, model design and training using CNN with MobileNetV3, and model evaluation with k-fold cross-validation ($k = 10$) to ensure reliable results. Experiments were conducted by applying the k-fold technique, and the best result was obtained at $k = 1$ with an accuracy of 98% and a loss value of 0.02, indicating that the developed model performs very well in classifying diseases in rice plants.

Keywords: Bacteria; Convolutional Neural Network (CNN); Identification; Fungi; Rice Plant Diseases.

1. PENDAHULUAN

Beras merupakan makanan pokok utama di banyak negara, termasuk Indonesia, sehingga permintaannya terus meningkat seiring pertumbuhan penduduk yang mencapai 265 juta jiwa (Chouhan *et al.*, 2021; Latif *et al.*, 2022; Sutardi *et al.*, 2023). Konsumsi beras memang mengalami peningkatan, namun produksi beras belum optimal karena kegagalan panen. Salah satu penyebab utama kegagalan tersebut adalah penyakit tanaman padi yang dapat menyebabkan kehilangan hasil panen hingga 10–15% (Deng *et al.*, 2021; Rahman *et al.*, 2020). Lebih dari 70 jenis penyakit padi telah teridentifikasi, disebabkan oleh berbagai patogen seperti jamur, bakteri, virus, dan mikoplasma. Penyakit yang umum dijumpai di Indonesia adalah Bacterial Leaf Blight dan Brown Spot, yang dapat menyerang sejak tahap pembibitan hingga panen (Latif *et al.*, 2022; Persaud *et al.*, 2022).

Penyakit pada tanaman padi umumnya ditandai dengan munculnya bercak pada daun, sehingga deteksi dini sangat penting untuk mencegah kerugian yang lebih besar. Keterbatasan dalam pengamatan manual di lahan yang luas serta risiko kesalahan manusia menyebabkan metode diagnosis penyakit secara tradisional menjadi kurang efektif dan cenderung mahal. Sistem otomatis yang mampu mengidentifikasi dan mengklasifikasi penyakit secara cepat, tepat, dan akurat menjadi solusi yang dibutuhkan. Teknologi seperti *artificial intelligence* (AI), khususnya *computer vision* dan *deep learning*, memungkinkan analisis gejala penyakit melalui citra daun tanaman yang dapat diakses dengan mudah oleh petani menggunakan kamera pada smartphone masing-masing (Deng *et al.*, 2021; Latif *et al.*, 2022; Nguyen *et al.*, 2023; Shrivastava *et al.*, 2019).

Convolutional Neural Network (CNN) merupakan metode *deep learning* yang banyak digunakan dalam klasifikasi gambar karena kemampuannya mengekstraksi fitur relevan langsung dari gambar mentah tanpa perlu tahapan pra-pemrosesan. Arsitektur berlapis pada CNN memungkinkan pembelajaran

otomatis dari fitur sederhana hingga kompleks, yang pada akhirnya dapat meningkatkan efisiensi dan akurasi (Liang *et al.*, 2019; Nguyen *et al.*, 2023). Sejumlah penelitian sebelumnya telah membuktikan efektivitas CNN, seperti yang dilakukan oleh Rahman *et al.* (2020) dengan akurasi 93,30% pada 1.426 gambar dan enam kelas penyakit padi, serta oleh Latif *et al.* (2022) yang mencapai akurasi 96,08% pada 2.167 gambar. Bukti-bukti tersebut semakin mengukuhkan CNN sebagai metode utama dalam klasifikasi citra di berbagai bidang.

CNN telah terbukti efektif untuk tugas klasifikasi gambar, tetapi penggunaannya pada perangkat dengan sumber daya terbatas seperti *smartphone* masih kurang optimal. Solusi atas keterbatasan tersebut adalah penggunaan arsitektur ringan seperti MobileNet, dengan MobileNetV3 sebagai versi terbarunya yang menggabungkan efisiensi, kecepatan, dan akurasi (Bhattacharai *et al.*, 2024; Chen *et al.*, 2021). MobileNet mampu memproses data secara *real-time* dengan konsumsi memori yang rendah, seperti ditunjukkan oleh studi Roseno *et al.* (2024) yang mencapai akurasi 79% meskipun dengan jumlah data yang kecil dan lima kelas. Kemampuannya tersebut menjadikannya ideal untuk implementasi langsung di lapangan oleh petani.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit padi yang dapat diimplementasikan pada perangkat *mobile*, dengan menggunakan *dataset* yang diperoleh dari *platform Kaggle*. Salah satu tantangan utama dalam pengembangan model ini adalah keterbatasan jumlah data yang tersedia, sehingga diperlukan strategi yang tepat untuk mencapai tingkat akurasi yang baik. Evaluasi performa model akan dilakukan melalui metode *k-fold cross-validation* guna memastikan hasil yang menyeluruh serta menemukan konfigurasi model yang paling optimal. Model yang dikembangkan diharapkan mampu membantu petani dalam mendiagnosa penyakit tanaman padi secara cepat dan akurat.

2. TINJAUAN PUSTAKA

A. Deep Learning

Deep learning terdiri dari lapisan pemrosesan yang dapat mempelajari fitur data melalui berbagai tingkat abstraksi. *Deep learning* adalah metode yang menggunakan jaringan saraf dalam menyelesaikan berbagai tugas, seperti pengenalan objek, pengenalan suara, klasifikasi, analisis sentimen, pengenalan wajah dan pembelajaran tanpa pengawasan (Indolia *et al.*, 2018). Teori *information bottleneck* (IB) menjelaskan bahwa setiap lapisan jaringan memproses informasi penting dari data masukan dan mempertahankan informasi yang relevan dengan hasil yang diinginkan. IB juga memberikan cara untuk mengevaluasi model dengan mengukur seberapa baik informasi tersebut disimpan dan digunakan (Saxe *et al.*, 2018).

B. Foreground

Foreground dalam segmentasi citra merujuk pada bagian gambar yang menjadi objek utama analisis, sedangkan *background* adalah bagian yang tidak memiliki relevansi utama dalam pemrosesan lebih lanjut. Dalam konteks klasifikasi penyakit tanaman padi, *foreground* adalah area yang berisi tanaman padi, termasuk daun tanaman padi, sementara *background* bisa berupa tanah, bayangan, atau elemen lingkungan lainnya. Segmentasi yang akurat sangat penting untuk menghindari kesalahan klasifikasi akibat pencampuran antara tanaman dan elemen *non-relevant* seperti tanah maupun lingkungan sekitar. Proses segmentasi yang baik akan memudahkan model dalam mengenali pola yang spesifik terhadap kondisi tanaman padi (Castillo-Martínez *et al.*, 2020)

C. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) atau *ConvNet* adalah jenis jaringan saraf yang terinspirasi oleh cara kerja otak manusia (Indolia *et al.*, 2018). *CNN* dapat mengidentifikasi, mengenali, dan mengklasifikasi objek serta mendeteksi dan mengelompokkan objek dalam gambar (Taye, 2023). Model umum *CNN* terdiri dari empat

komponen yaitu *convolution layer*, *pooling layer*, *activation function* dan *fully connected layer* (Indolia *et al.*, 2018; Sharma *et al.*, 2018).

a. *Convolution layer*, lapisan ini menggunakan kernel untuk mengekstraksi fitur dari gambar dengan operasi konvolusi, di mana bobot kernel disesuaikan selama pelatihan untuk mengenali karakteristik data input (Nawrocka *et al.*, 2023; Taye, 2023).

b. *Pooling layer*, lapisan ini bertujuan untuk mengurangi jumlah parameter dan komputasi dalam jaringan, mencegah *overfitting* serta mempercepat proses pelatihan (Yani *et al.*, 2019).

c. *Activation function*, berfungsi untuk mengubah output lapisan sebelumnya menjadi *non-linear* untuk memodelkan masalah kompleks, dengan fungsi seperti *sigmoid*, *tanh*, dan *ReLU* yang masing-masing memiliki karakteristik dan manfaat berbeda dalam pengolahan data (Nawrocka *et al.*, 2023; Taye, 2023).

d. *Fully connected layer*, bertindak sebagai pengklasifikasi di *CNN*. Tujuan lapisan ini adalah menggabungkan fitur-fitur yang telah diekstraksi dari data oleh lapisan-lapisan sebelumnya dan kemudian menghasilkan *output* lain (Nawrocka *et al.*, 2023).

D. MobileNetV3

MobileNet adalah jaringan saraf ringan yang dirancang untuk perangkat dengan keterbatasan daya dan komputasi seperti ponsel dan perangkat *IoT*, dengan *MobileNetV3* sebagai versi terbaru yang menggabungkan inovasi *Neural Architecture Search (NAS)* dan *Squeeze-and-Excitation (SE) Module*. *NAS* digunakan untuk merancang arsitektur jaringan yang optimal, mengeksplorasi berbagai konfigurasi jaringan, sementara *SE Module* meningkatkan representasi fitur dengan memberi perhatian pada fitur yang relevan (Howard *et al.*, 2019).

Fungsi aktivasi yang digunakan pada *NAS* ialah *h-swish*. Fungsi *h-swish* digunakan untuk mempercepat komputasi dengan menggantikan operasi *non-linear* kompleks, menggunakan formula: $h\text{-swish}(\chi) = \chi(\text{ReLU6}(\chi + 3))/6$. *MobileNetV3* juga mengintegrasikan *NAS* untuk menemukan blok konvolusi optimal dan

SE Module yang terdiri dari tiga tahap—*squeeze*, *excitation*, dan *reweight*—untuk meningkatkan fokus model pada fitur penting (Hu *et al.*, 2020).

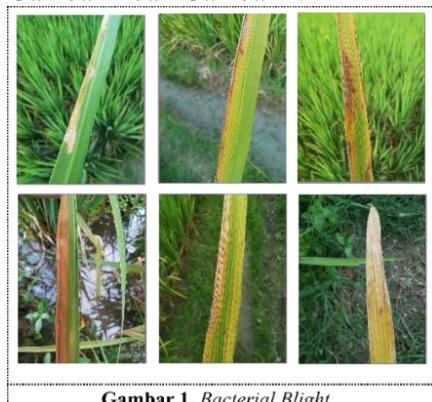
E. K-Fold Cross Validation

k-fold cross validation adalah teknik umum dalam pembelajaran mesin untuk mengevaluasi model secara optimal. Metode ini membagi data menjadi k bagian, di mana setiap bagian bergantian menjadi data testing sementara sisanya sebagai data *training*. *K-fold cross validation* dapat meningkatkan akurasi prediksi, dengan $k = 7$ dianggap sebagai estimasi yang lebih akurat dibanding $k = 5$ atau 10 (Nti *et al.*, 2021; Wayahdi *et al.*, 2020).

3. METODE PENELITIAN

A. Pengumpulan Data

Penelitian ini menggunakan *Rice Disease Dataset* dari Kaggle yang terdiri atas dua kelas penyakit daun padi, yaitu *Bacterial Leaf Blight* (498 gambar) dan *Brown Spot* (500 gambar), dengan format gambar RGB. Data yang telah diunduh kemudian diimpor dengan membaca struktur direktori yang telah terorganisir berdasarkan masing-masing kelas. Seluruh *path* gambar beserta labelnya dikumpulkan dan disusun ke dalam sebuah *dataframe* menggunakan pustaka *os* untuk mengakses *file* serta direktori, dan pustaka *pandas* untuk mengelola serta memanipulasi data agar siap digunakan dalam proses pelatihan model. Contoh citra dari masing-masing kelas penyakit tanaman padi dapat dilihat pada Gambar 1 dan Gambar 2.



Gambar 1. Bacterial Blight

Gambar 1. Bacterial Blight
Sumber: Rice Disease Dataset, 2024



Gambar 2. Brown Spot

Gambar 2. Brown spot

Sumber: Rice Disease Dataset, 2024

B. Preprocessing Data

Preprocessing data merupakan tahap penting sebelum data citra digunakan dalam pelatihan model. Langkah-langkah yang dilakukan pada tahap ini meliputi *foreground extraction*, augmentasi data, dan proses konvolusi. Setiap langkah memiliki peran khusus dalam menyiapkan data agar lebih representatif dan optimal untuk proses pembelajaran mesin. Tujuan dari tahap ini adalah untuk meningkatkan kualitas data, mengurangi *noise*, serta memastikan model memperoleh variasi dan distribusi data yang baik demi meningkatkan akurasi dan kemampuan generalisasi.

Pada tahap *foreground*, proses difokuskan untuk memisahkan objek utama berupa tanaman padi dari *background* gambar. Proses ini dilakukan dengan mengonversi citra ke ruang warna LAB, meningkatkan kontras menggunakan algoritma CLAHE, dan menerapkan metode segmentasi seperti GrabCut untuk menandai area tanaman. Hasil akhir berupa citra yang lebih bersih dengan objek tanaman sebagai fokus utama, sementara *background* dihilangkan atau dihitamkan guna mendukung analisis yang lebih akurat.

Langkah augmentasi data dilakukan untuk memperkaya jumlah dan variasi data pelatihan dengan memodifikasi gambar-gambar yang ada tanpa mengubah label aslinya. Teknik ini bertujuan untuk meningkatkan kemampuan generalisasi model CNN MobileNetV3 dalam mengklasifikasikan penyakit pada tanaman

padi, terutama ketika jumlah data yang tersedia relatif kecil. Tahap ini juga mengubah rentang piksel dari 0–255 menjadi –1 hingga 1.

Langkah terakhir adalah melakukan ekstraksi fitur menggunakan operasi konvolusi dengan arsitektur MobileNetV3Small sebagai *base model*. Model ini membaca informasi spasial dan fitur penting dari gambar, seperti tepi, pola, dan tekstur, melalui *layer* seperti Conv2D, DepthwiseConv2D, dan PointwiseConv2D. Setiap *layer* menghasilkan *feature map* yang merepresentasikan citra secara bertahap. MobileNetV3Small digunakan tanpa bagian *top classifier* (include_top=False), sehingga hasil ekstraksi dapat disesuaikan untuk kebutuhan klasifikasi dalam penelitian ini.

C. Training Model

Tahap ini mencakup perancangan dan pembangunan arsitektur model menggunakan pustaka TensorFlow dan Keras. Model dasar yang digunakan adalah MobileNetV3 karena kemampuannya dalam mengekstraksi fitur kompleks secara efisien. Arsitektur model terdiri dari *initial convolution block* untuk menangkap fitur awal, diikuti oleh 11 *bottleneck blocks* yang berfungsi memperdalam ekstraksi fitur, serta final *convolution block* sebagai penyempurna sebelum tahap klasifikasi. Selanjutnya, diterapkan *global average pooling* untuk mereduksi dimensi, yang kemudian dilanjutkan dengan *fully connected layers* yang terdiri dari tiga *dense layer* dan dua *dropout layer* untuk proses klasifikasi. Secara keseluruhan, terdapat 19 lapisan dalam arsitektur ini. Model ini dirancang untuk mengklasifikasikan gambar tanaman padi yang terkena penyakit Brown Spot dan Bacterial Leaf Blight.

Untuk menghindari *overfitting* selama proses *training* model, digunakan metode *k-fold cross-validation* dengan nilai parameter *k* = 10. *Dataset* dibagi menjadi lima bagian, di mana masing-masing bagian secara bergantian digunakan sebagai data *validation*, sementara sisanya digunakan untuk *training*. Hasil dari setiap iterasi dirata-rata untuk memperoleh performa model yang lebih akurat. Evaluasi

model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*, yang secara bersama-sama memberikan gambaran menyeluruh tentang ketepatan dan keseimbangan performa prediksi model.

D. Pengembangan Sistem

Pada tahap implementasi, model dengan performa terbaik yang telah dilatih diintegrasikan ke dalam aplikasi *mobile* melalui beberapa tahapan penting. Proses dimulai dengan mendesain antarmuka pengguna menggunakan *Figma* untuk memastikan tampilan aplikasi menarik, responsif, dan mudah digunakan. Desain ini mencakup pemilihan warna, pengaturan elemen visual, serta penataan *layout* yang nyaman bagi pengguna. Setelah desain selesai, dibuat *API* menggunakan pustaka Python Flask untuk menjembatani komunikasi antara aplikasi dan model *CNN MobileNetV3*. *API* ini berfungsi untuk mengirimkan data gambar dari aplikasi ke *server*, memprosesnya dengan model, dan mengembalikan hasil prediksi ke perangkat pengguna.

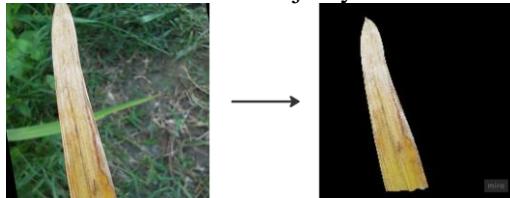
Setelah itu, dilakukan proses *slicing* dan integrasi, yaitu menerjemahkan desain antarmuka ke dalam kode menggunakan *React Native* dan *TypeScript*. Dengan *React Native*, aplikasi dapat dikembangkan untuk *platform* Android dan iOS secara bersamaan. Setelah desain diimplementasikan, *API* yang telah dibangun kemudian diintegrasikan ke dalam antarmuka, memungkinkan aplikasi mengirim gambar dan menerima hasil prediksi secara *real-time*. Terakhir, dilakukan tahap pengujian untuk memastikan seluruh sistem berjalan optimal. Pengujian mencakup fungsionalitas aplikasi, performa *API*, serta akurasi prediksi model, dengan bantuan *tools* seperti *React DevTools* untuk memantau performa aplikasi, mengidentifikasi hambatan, dan meningkatkan efisiensi penggunaan sumber daya.

4. HASIL DAN PEMBAHASAN

A. Preprocessing Data

Hasil dari tahap *preprocessing* menunjukkan bahwa gambar telah berhasil dipisahkan antara objek tanaman padi dan latar belakang, dengan latar belakang yang telah

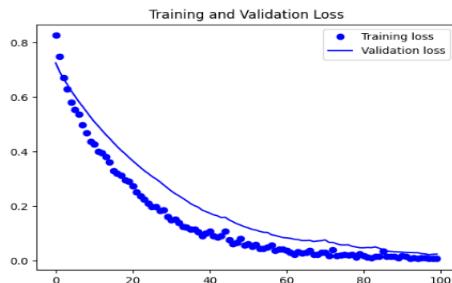
dihapus sebagaimana ditampilkan pada Gambar 3. Setelah proses ini, data dari kedua kelas (Bacterial Leaf Blight dan Brown Spot) kini memiliki jumlah gambar yang seimbang, sehingga memastikan bahwa *dataset* siap digunakan untuk pelatihan model tanpa adanya ketidakseimbangan antar kelas. Data yang telah diproses ini memiliki kualitas yang lebih baik untuk analisis selanjutnya.



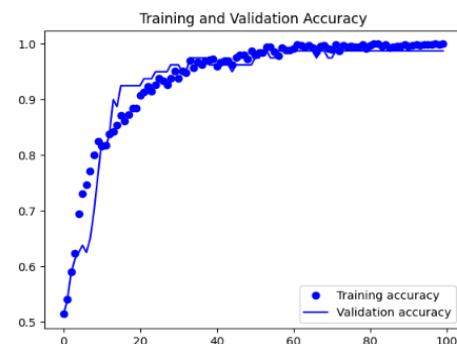
Gambar 3. Hasil proses *foreground extraction*
Sumber: Hasil Penelitian, 2025.

B. Training model

Hasil pelatihan menghasilkan lima model berdasarkan nilai parameter k yang berbeda. Di antara kelima model tersebut, model dengan nilai $k = 1$ menunjukkan performa terbaik dengan akurasi sebesar 98% dan nilai *loss* yang sangat rendah, yaitu 0,02. Hasil ini mengindikasikan bahwa model mampu mengklasifikasikan gambar dengan sangat baik, baik pada data pelatihan maupun data validasi. Grafik pada Gambar 4 menampilkan penurunan *training loss* dan *validation loss* secara konsisten seiring bertambahnya *epoch*, menunjukkan bahwa proses pembelajaran berjalan stabil tanpa indikasi *overfitting*. Sementara itu, Gambar 5 memperlihatkan bahwa akurasi model meningkat tajam pada awal *epoch* dan terus naik mendekati nilai maksimal, menandakan kemampuan generalisasi model terhadap data validasi yang sangat baik.



Gambar 4. *Training and validation loss*
Sumber: Hasil Penelitian, 2025.



Gambar 5. *Training and validation accuracy*
Sumber: Hasil Penelitian, 2025.

Dibandingkan dengan model lainnya, meskipun model dengan nilai $k = 3$ berhasil mencapai akurasi hingga 100%, nilai *loss*-nya masih berada di angka 0,003. Hal ini menyebabkan grafik akurasi training dan validation cenderung memiliki jarak yang lebih besar, yang menandakan potensi kurang stabilnya generalisasi model tersebut. Oleh karena itu, meskipun secara akurasi terlihat sangat tinggi, model dengan $k = 3$ tidak lebih unggul dibandingkan model dengan $k = 1$ dalam hal kestabilan dan kesesuaian antara data pelatihan dan data validasi. Secara keseluruhan, model dengan $k = 1$ dinilai sebagai model paling optimal karena memiliki keseimbangan antara akurasi tinggi, nilai *loss* rendah, dan grafik performa yang konsisten selama proses pelatihan dan validasi. Hasil performa model untuk nilai parameter k lainnya dapat dilihat pada Tabel 1.

Perlu dicatat bahwa proses *training* model hanya dilakukan hingga nilai $k = 5$. Hal ini disebabkan adanya fungsi *early stopping* yang secara otomatis menghentikan proses pelatihan apabila tidak terdapat peningkatan performa yang signifikan pada model selama beberapa iterasi. Mekanisme ini diterapkan untuk mencegah *overfitting* dan mengoptimalkan efisiensi waktu pelatihan.

Tabel 1. Performa model per nilai- k

No	Nilai k	Accuracy	Loss
1	$k - 2$	67%	0.54
2	$k - 3$	100%	0.03
3	$k - 4$	97%	0.07
4	$k - 5$	83%	0.32

Sumber: Hasil Penelitian, 2025.

C. Implementasi Sistem

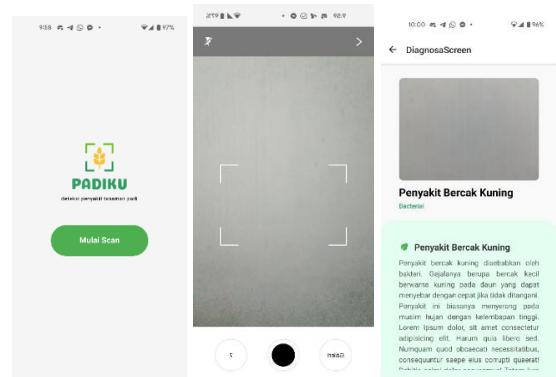
Tahap implementasi model terbaik ke dalam aplikasi *mobile* mencakup empat langkah utama. Langkah pertama adalah perancangan antarmuka (*UI/UX*) yang bertujuan untuk memastikan kemudahan penggunaan serta penyajian hasil prediksi model secara intuitif. Desain *high-fidelity* mencakup tata letak, navigasi, dan elemen visual utama, sebagaimana ditampilkan pada Gambar 6 yang menunjukkan rancangan antarmuka aplikasi.



Gambar 6. Design rancangan UI/UX aplikasi
Sumber: Hasil Penelitian, 2025.

Langkah kedua adalah pengembangan *API* yang berfungsi untuk menghubungkan model dengan aplikasi. *API* ini dirancang untuk menerima input berupa gambar, memprosesnya, dan mengirimkan hasil prediksi secara *real-time*. Dokumentasi lengkap disusun untuk memudahkan proses integrasi serta memastikan bahwa *API* tetap efisien dan aman.

Langkah ketiga adalah proses *slicing* dan integrasi *API*, yang bertujuan untuk mengubah desain *UI* menjadi komponen interaktif menggunakan *React Native*. Setelah proses *slicing* selesai, *API* diintegrasikan ke dalam aplikasi untuk mengirim dan menerima data prediksi. Hasil akhir ditampilkan langsung di antarmuka pengguna, sebagaimana terlihat pada tangkapan layar aplikasi dalam Gambar 7. Tahapan ini mengimplementasikan desain *UI/UX* sistem kedalam kode pemrograman, fungsionalitas masing-masing fitur, dan hasil prediksi model klasifikasi penyakit tanaman padi ke dalam aplikasi *mobile* yang siap digunakan.



Gambar 7. Tangkapan layar aplikasi Padiku
Sumber: Hasil Penelitian, 2025.

5. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan analisa data dan pembahasan, maka didapatkan beberapa kesimpulan sebagai berikut :

1. Model klasifikasi penyakit tanaman padi yang dikembangkan menggunakan *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNetV3* berhasil mencapai akurasi terbaik sebesar 98%. Capaian ini diperoleh melalui serangkaian proses *preprocessing* menggunakan teknik *resize* dan *foreground extraction*, serta pelatihan dan validasi model menggunakan metode *k-fold cross-validation* pada *dataset* yang telah dikumpulkan.
2. Penggunaan metode *k-fold cross-validation* memberikan pengaruh signifikan terhadap performa model. Berdasarkan hasil eksperimen dengan beberapa nilai *k*, diketahui bahwa nilai *k* = 1 menghasilkan performa terbaik secara keseluruhan. Model terbaik tersebut dibangun menggunakan arsitektur *Convolutional Neural Network (CNN)* berbasis *MobileNetV3*, dengan parameter pelatihan meliputi *optimizer Adam*, jumlah *epoch* sebanyak 100, *batch size* sebesar 32, dan *learning rate* sebesar 0,001.
3. Model klasifikasi yang telah dilatih berhasil diimplementasikan ke dalam aplikasi *mobile* menggunakan *React Native*. Model ini mampu

mengklasifikasikan gambar penyakit tanaman padi secara *real-time*, dengan waktu *inference* rata-rata sebesar 0,45 detik.

B. Saran

1. Pengujian model perlu dilakukan menggunakan gambar dalam berbagai kondisi, seperti pencahayaan redup, gambar buram, dan variasi latar belakang. Pengujian ini bertujuan untuk meningkatkan kemampuan model dalam mengenali penyakit tanaman padi secara lebih akurat di situasi nyata, sehingga aplikasi dapat digunakan secara optimal dalam berbagai kondisi lingkungan.
2. Penambahan mekanisme validasi input diperlukan untuk memastikan bahwa gambar yang diunggah merupakan citra tanaman padi. Sistem perlu dirancang agar dapat mendeteksi input yang tidak relevan dan memberikan peringatan kepada pengguna jika gambar yang diunggah bukan merupakan objek yang sesuai.
3. Variasi sudut pengambilan gambar tanaman padi diperlukan untuk memungkinkan identifikasi pola bentuk dan karakteristik tanaman secara lebih menyeluruh. Jenis penyakit tidak hanya terdeteksi dari kondisi daun, tetapi juga dapat terlihat pada bagian batang dan akar. Oleh karena itu, pengambilan gambar dari berbagai sudut bertujuan untuk meningkatkan akurasi model dalam mengenali penyakit berdasarkan visualisasi yang lebih komprehensif.

6. DAFTAR PUSTAKA

- Bhattarai, Y., Prasun, K., Sharma, G., & Rai, P. 2024. Enhancing Rice Disease Binary Classification. an Analysis of Deep Neural Network Models. *International Journal of Research Publications*, 147(1): 111-115.
- Castillo-Martínez, M., Gallegos-Funes, F. J., Carvajal-Gámez, B. E., Uriolagoitia-Sosa, G., & Rosales-Silva, A. J. 2020. Color Index Based Thresholding Method For Background and Foreground Segmentation of Plant Images. *Computers and Electronics in Agriculture*. 11(4): 20-21.
- Chen, J., Zhang, D., Zeb, A., & Nanehkaran, Y. A. 2021. Identification of Rice Plant Diseases Using Lightweight Attention Networks. *Expert Systems with Applications*. 12(2): 10-11.
- Chouhan, V., Kumar, A., & Singh, R. 2021. Evaluation of Fungicides for Management of Brown Leaf Spot Disease of Rice. *Middle East Journal of Applied Science & Technology*. 4(4): 75–79.
- Deng, R., Tao, M., Xing, H., Yang, X., Liu, C., Liao, K., & Qi, L. 2021. Automatic Diagnosis of Rice Diseases Using Deep Learning. *Frontiers in Plant Science*. 12(5): 5-8.
- Gavrilov, A. D., Jordache, A., Vasdani, M., & Deng, J. 2019. Preventing Model Overfitting and Underfitting in Convolutional Neural Networks. *International Journal of Software Science and Computational Intelligence*. 10(4): 19–28.
- Ghorbani, F., Shabani, J., Beyraghi, S., Soleimani, H., Oraizi, H., & Soleimani, M. 2021. A deep learning approach for inverse design of the metasurface for dual-polarized waves. *Applied Physics A: Materials Science and Processing*. 127(11): 50 – 58.
- Howard, A., Wang, W., Chu, G., Chen, L., Chen, B., & Tan, M. 2019. Searching for MobileNetV3 Accuracy vs MADDs vs model size. *International Conference on Computer Vision*. 110(11): 1314–1324.
- Hu, J., Shen, L., Albanie, S., Sun, G., & Wu, E. 2020. Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 42(8): 2011–2023.
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P. 2018. Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science*. 132(4): 679–688.
- Latif, G., Abdelhamid, S. E., Mallouhy, R. E., Alghazo, J., & Kazimi, Z. A. 2022. Deep Learning Utilization in Agriculture:

- Detection of Rice Plant Diseases Using an Improved CNN Model. *Plants*. 11(17): 80-88.
- Liang, W. jie, Zhang, H., Zhang, G. feng, & Cao, H. xin. 2019. Rice Blast Disease Recognition Using a Deep Convolutional Neural Network. *Scientific Reports*. 9(1): 1–11.
- Liu, Z., Shen, Z., Li, S., Helwegen, K., Huang, D., & Cheng, K.-T. 2021. How Do Adam and Training Strategies Help BNNs Optimization. International Conference on Machine Learning. 18-24 July 2021, Vienna, Austria. Hal 90-95.
- Luu, N. D., Thi, L., Diem, T., Thi, H., & Anh, P. 2024. Application Of Deep Learning For Rice Leaf Disease Detection In The Mekong Delta. *CTU Journal of Innovation and Sustainable Development*. 16: 1–7.
- Naqvi, S. A. H., Umar, U. ud D., Hasnain, A., Rehman, A. ur, & Perveen, R. 2019. Effect of Botanical Extracts: A Potential Biocontrol Agent for *Xanthomonas Oryzae* Pv. *Oryzae*, Causing Bacterial Leaf Blight Disease of Rice. *Pakistan Journal of Agricultural Research*. 32(1): 59–72.
- Nawrocka, A., Nawrocki, M., & Kot, A. 2023. Research study of image classification algorithms based on Convolutional Neural Networks. *Proceedings of the 2023 24th International Carpathian Control Conference, ICCC*. 2023: 299–302.
- Nguyen, H. L., Tran, T. H., Thi, H. H. Le, & Nguyen, D. C. 2023. From a Proposed CNN Model to a Real-World Application in Rice Disease Classification. *Proceedings of the Seventh International Conference on Research in Intelligent and Computing in Engineering*. 33: 177–182.
- Nti, I. K., Nyarko-Boateng, O., & Aning, J. 2021. Performance of Machine Learning Algorithms with Different K Values in K-fold CrossValidation. *International Journal of Information Technology and Computer Science*. 13(6): 61–71.
- Persaud, R., Payman, G., Khan, A., Singh, N., Persaud, D. A., & Subramanian, G. 2022. Effectiveness of new fungicides and neem plant aqueous extract against brown spot disease of rice. *International Journal of Agricultural Policy and Research*. 11(1): 1–15.
- Quach, L. Da, Quoc, K. N., Quynh, A. N., & Ngoc, H. T. 2022. Evaluation of the Efficiency of the Optimization Algorithms for Transfer Learning on the Rice Leaf Disease Dataset. *International Journal of Advanced Computer Science and Applications*. 13(10): 83–91.
- Rahman, C. R., Arko, P. S., Ali, M. E., Iqbal Khan, M. A., Apon, S. H., Nowrin, F., & Wasif, A. 2020. Identification and recognition of rice diseases and pests using convolutional neural networks. *Biosystems Engineering*. 194: 112–120.
- Roseno, M. T., Oktarina, S., Nearti, Y., & Jayanti, N. 2024. Comparing CNN Models for Rice Disease Detection. *Journal of Information Systems and Informatics*. 6(3): 2099–2109.
- Saxe, A. M., Bansal, Y., Dapello, J., Advani, M., Kolchinsky, A., Tracey, B. D., & Cox, D. D. 2018. on the Information Bottleneck Theory of Deep Learning. *Journal of Statistical Mechanics: Theory and Experiment (JSTAT)*. 12(5): 56-80.
- Sharma, N., Jain, V., & Mishra, A. 2018. An Analysis of Convolutional Neural Networks for Image Classification. *Procedia Computer Science*. 132(4): 377–384.
- Sharma, R., Singh, A., Kavita, Jhanjhi, N. Z., Masud, M., Jaha, E. S., & Verma, S. 2022. Plant Disease Diagnosis and Image Classification Using Deep Learning. *Computers, Materials and Continua*. 71(2): 2125–2140.
- Shrivastava, V. K., Pradhan, M. K., Minz, S., & Thakur, M. P. 2019. Rice Plant Disease Classification Using Transfer Learning of Deep Convolution Neural Network. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. 42(3): 631–635.
- Sreenivas, A. 2020. Indian Sign Language Communicator Using Convolutional Neural Network. *International Journal of*

- Advanced Science and Technology.* 29(3): 11015–11031.
- Sudhasha, S., Balabaskar, P., Kumar, K. S., & Sivakumar, T. 2020. Prevalence of Rice Brown Spot Disease Incidence in Northern Districts of Tamilnadu. *India and Observations on Morpho Pathogenic Variability Among Isolates of Bipolaris Oryzae.* 20: 3819–3825.
- Sutardi, Apriyana, Y., Rejekiningrum, P., Alifia, A. D., Ramadhani, F., Darwis, V., Setyowati, N., Setyono, D. E. D., Gunawan, Malik, A., Abdullah, S., Muslimin, Wibawa, W., Triastono, J., Yusuf, Arianti, F. D., & Fadwiwati, A. Y. 2023. *The Transformation of Rice Crop Technology in Indonesia: Innovation and Sustainable Food Security.* 13(1): 1–14.
- Taye, M. M. 2023. Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation,* 11(3): 180–190.
- Walascha, A., Febriana, A., Saputri, D., Sri Nur Haryanti, D., Tsania, R., Sanjaya, Y., & Priyanti. 2021. Review Artikel: Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi (*Oryza sativa* L.). *Prosiding Seminar Nasional Biologi.* 1(2): 471–478.
- Wang, Y., Wang, H., & Peng, Z. 2021. Rice diseases detection and classification using attention based neural network and bayesian optimization. *Expert Systems with Applications.* 178(3): 1147.
- Wayahdi, M. R., Syahputra, D., Hafiz, S., & Ginting, N. 2020. Evaluation of the K-Nearest Neighbor Model With K-Fold Cross Validation on Image Classification. *Infokum.* 9(1): 1–6.
- Yani, M., Irawan, B., & Setiningsih, C. 2019. Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail. *Journal of Physics: Conference Series.* 1201(1): 111-119.