

Implementasi CNN dan *TensorFlow Lite* untuk Deteksi Penyakit Daun Padi Berbasis Android

Fathur Rizal¹, M. Latip Sa'idi², Moh. Umzeb Rizki Hidayat³
^{1,2,3} Universitas Nurul Jadid, Indonesia

Info Artikel	ABSTRAK
<u>Riwayat Artikel</u>	
Diterima: 11-10-2025	
Disetujui: 20-12-2025	
<u>Kata Kunci</u>	
<i>Android;</i> <i>Convolutional Neural Network;</i> <i>Disease Detection;</i> <i>Image Processing;</i> <i>TensorFlow Lite.</i>	Penyakit pada daun padi seperti <i>Bacterial Leaf Blight</i> , <i>Brown Spot</i> , dan <i>Leaf Smut</i> masih menjadi ancaman signifikan bagi produktivitas pertanian di Indonesia. Identifikasi konvensional yang mengandalkan observasi visual oleh petani maupun penyuluh bersifat subjektif, memerlukan waktu, dan kurang efisien, khususnya di wilayah terpencil. Menjawab tantangan tersebut, penelitian ini mengembangkan sistem deteksi penyakit daun padi berbasis <i>Convolutional Neural Network</i> (CNN) yang dioptimalkan melalui <i>TensorFlow Lite</i> dan diimplementasikan pada aplikasi Android. Pendekatan yang digunakan bersifat kuantitatif-eksperimental dengan tahapan utama meliputi pengumpulan serta pra-pemrosesan citra daun padi, pelatihan model CNN untuk tiga kelas penyakit, konversi model ke format .tflite, dan integrasi ke dalam aplikasi. Dataset bersumber dari platform Kaggle dengan total 4.684 citra yang dibagi secara proporsional untuk pelatihan, validasi, dan pengujian. Evaluasi kinerja dilakukan menggunakan metrik <i>accuracy</i> , <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> . Hasil menunjukkan bahwa model yang dikembangkan mampu mengklasifikasikan ketiga kelas penyakit dengan akurasi uji 99%. Implementasi pada Android memungkinkan pengguna mengunggah atau mengambil citra secara langsung untuk dianalisis <i>offline</i> dan <i>real-time</i> , dengan antarmuka yang ringkas dan mudah digunakan. Secara keseluruhan, sistem deteksi berbasis CNN dan <i>TensorFlow Lite</i> ini terbukti efektif untuk diagnosis penyakit daun padi serta berpotensi menjadi solusi portabel yang mendukung praktik pertanian presisi di lapangan.
fathurrizal@unuja.ac.id	

1. PENDAHULUAN

Padi merupakan komoditas strategis sekaligus sumber utama karbohidrat bagi sebagian besar penduduk Indonesia dan dunia [1], [2]. Keberlangsungan produktivitas padi sangat ditentukan oleh kesehatan tanamannya, terutama kondisi daun yang berperan penting dalam proses fotosintesis. Sayangnya, daun tanaman padi sangat rentan terhadap serangan berbagai penyakit, seperti *blast* (penyakit blas), *bacterial leaf blight* (hawar daun bakteri), dan *brown spot* (bercak cokelat) [3], [4], [5]. Ketiga penyakit ini bukan hanya menghambat pertumbuhan tanaman, tetapi juga berpotensi menurunkan hasil panen secara signifikan jika tidak terdeteksi dan ditangani sejak dini.

Selama ini, proses identifikasi penyakit daun padi di lapangan masih didominasi oleh observasi visual oleh petani atau tenaga penyuluh [3], [6]. Pendekatan tersebut memiliki banyak keterbatasan: bersifat subjektif, membutuhkan keahlian khusus, dan sulit diterapkan secara cepat di area pertanian yang luas. Di era revolusi industri 4.0, kondisi ini menuntut adanya solusi berbasis teknologi yang mampu mengotomatiskan proses deteksi penyakit secara akurat

dan efisien. Salah satu pendekatan yang tengah berkembang pesat adalah penerapan kecerdasan buatan, khususnya *Deep Learning*, dalam analisis citra pertanian [7]. Dengan memanfaatkan kemampuan model *Convolutional Neural Network* (CNN) dalam mengenali pola visual kompleks, sistem komputer dapat dilatih untuk mengklasifikasikan jenis penyakit daun tanaman secara presisi [8], [9]. Bahkan, beberapa penelitian menunjukkan bahwa akurasi model deep learning dapat menyamai bahkan melampaui diagnosis manusia.

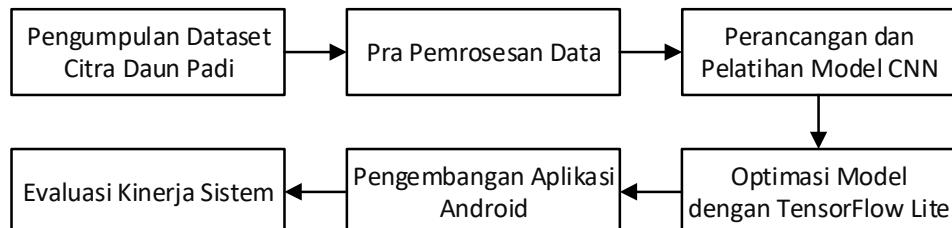
Penelitian oleh Mohanty dkk, membuktikan bahwa CNN dapat mengidentifikasi 26 penyakit pada 14 jenis tanaman menggunakan dataset PlantVillage dengan akurasi tinggi [10]. Hal ini diperkuat oleh Ferentinos yang mengevaluasi berbagai arsitektur CNN dan melaporkan akurasi lebih dari 99% dalam mendeteksi penyakit tanaman secara otomatis [11]. Penelitian-penelitian tersebut menunjukkan bahwa teknologi deep learning sangat potensial untuk digunakan dalam pengolahan citra daun tanaman, termasuk padi. Khusus untuk tanaman padi, Putra dkk, berhasil mengembangkan model CNN berbasis TensorFlow untuk mengklasifikasikan daun padi sehat, blas, dan hawar daun bakteri, dengan akurasi mencapai 96% [12]. Studi serupa [5] menunjukkan efektivitas CNN dalam mengidentifikasi penyakit daun padi dari citra digital, memperkuat posisi teknologi ini sebagai alat diagnosis modern yang dapat diandalkan.

Namun demikian, sebagian besar model *deep learning* tersebut masih bergantung pada infrastruktur komputasi besar seperti desktop atau server dengan *Graphics Processing Unit* (GPU), sehingga kurang sesuai untuk kebutuhan di lapangan, terutama di daerah pedesaan. Untuk menjawab tantangan tersebut, *TensorFlow Lite* hadir sebagai solusi optimalisasi model *deep learning* ke dalam format ringan yang dapat dijalankan langsung di perangkat Android. Hal ini membuka peluang untuk membangun aplikasi deteksi penyakit tanaman yang portabel, praktis, dan dapat diakses oleh petani tanpa koneksi internet. Penelitian oleh Muslim dkk, menunjukkan bahwa model CNN yang telah dioptimalkan menggunakan *TensorFlow Lite* mampu berjalan efisien pada perangkat Android untuk mendeteksi penyakit daun kopi secara real-time [13]. Sementara itu, Pardede dkk menekankan pentingnya adopsi sistem cerdas berbasis *mobile* agar teknologi ini benar-benar bisa digunakan secara luas oleh pelaku pertanian[14].

Berdasarkan urgensi tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi dan klasifikasi penyakit daun tanaman padi berbasis CNN yang dioptimalkan menggunakan *TensorFlow Lite* dan diimplementasikan dalam aplikasi Android. Dengan pendekatan ini, diharapkan petani dapat melakukan diagnosis penyakit daun secara cepat, akurat, dan mandiri di lapangan, sehingga meningkatkan produktivitas dan ketahanan pangan secara berkelanjutan

2. METODE

Pendekatan dalam penelitian ini bersifat eksperimental terapan, yang bertujuan untuk membangun dan menguji sistem klasifikasi penyakit daun padi berbasis citra digital. Penelitian dilakukan secara bertahap berdasarkan alur proses yang sistematis, seperti yang tergambar dalam diagram tahapan berikut:



Gambar 1. Tahapan Penelitian

a. Pengumpulan Dataset

Proses dimulai dengan pengumpulan dataset citra daun padi dari sumber data publik yang tersedia di platform *Kaggle* [15]. Dataset ini mencakup gambar daun padi yang diklasifikasikan ke dalam beberapa kategori seperti *Bacterial Blight*, *Brown Spot*, and *Leaf Smut*. Jumlah keseluruhan citra yang digunakan dalam penelitian ini sebanyak 4.684 citra penyakit daun padi.

b. Pra-pemrosesan Data

Citra yang diperoleh dari dataset kemudian melalui tahap pra-pemrosesan, yang meliputi *resize*, normalisasi, augmentasi, dan konversi warna. Tahapan ini bertujuan untuk meningkatkan kualitas data agar sesuai dengan kebutuhan pelatihan model CNN dan untuk memperkaya variasi data melalui augmentasi.

c. Pembuatan dan Pelatihan Model

Model CNN dirancang dan dilatih menggunakan *framework TensorFlow*. Arsitektur CNN disesuaikan untuk klasifikasi multi-kelas sesuai kategori penyakit daun. Proses pelatihan menggunakan dataset yang telah diproses sebelumnya dan menghasilkan model awal yang akan digunakan sebagai basis untuk tahap selanjutnya.

d. Optimasi Model dengan TensorFlow Lite

Model yang telah dilatih kemudian dioptimalkan menggunakan *TensorFlow Lite*. Optimalisasi ini dilakukan melalui proses konversi, *quantization*, dan *pruning* untuk memperkecil ukuran model serta mempercepat proses inferensi, sehingga model dapat dijalankan secara efisien pada perangkat Android.

e. Pengembangan Aplikasi Android

Model hasil optimasi diintegrasikan ke dalam aplikasi Android dengan antarmuka yang sederhana dan fungsional. Aplikasi ini memungkinkan pengguna mengambil gambar daun padi melalui kamera *smartphone* dan secara otomatis mengklasifikasikan jenis penyakit yang terdeteksi secara *offline*.

f. Evaluasi Kinerja

Model yang telah dikembangkan dievaluasi menggunakan data uji berdasarkan kinerja klasifikasi model secara kuantitatif, menggunakan metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score*. Evaluasi dilakukan pada perangkat Android untuk mengukur efektivitas implementasi *real-time* secara langsung di lingkungan *mobile*.

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

$$\text{precision} = \frac{TP}{TP+F} \quad (2)$$

$$\text{recall} = \frac{TP}{TP+F} \quad (3)$$

Tahapan ini memungkinkan pengembangan sistem yang terintegrasi dari tahap konseptual hingga implementatif, dengan pengujian performa berbasis data objektif. Seluruh tahapan difokuskan untuk menghasilkan solusi praktis dan efisien yang dapat dimanfaatkan langsung oleh pengguna di sektor pertanian.

3. HASIL DAN PEMBAHASAN

A. Pengumpulan Dataset

Pengumpulan data dilakukan melalui sumber terbuka, yaitu platform *Kaggle*, dengan mengunduh dataset *Rice Plant Diseases Dataset* dari tautan berikut[15]:

<https://www.kaggle.com/datasets/jay7080dev/rice-plant-diseases-dataset>

Dataset ini dipilih karena memiliki karakteristik yang sesuai dengan kebutuhan penelitian, yaitu menyediakan gambar daun padi yang telah diklasifikasikan ke dalam beberapa jenis kondisi.

Tabel 1. Jumlah Dataset Citra Daun Padi

No.	Kelas	Jumlah Citra
1.	<i>Bacterial Leaf Blight</i>	1.604
2.	<i>Brown Spot</i>	1.620
3.	<i>Leaf Smut</i>	1.460
	Total	4.684

Jumlah total citra pada dataset tersebut sebanyak 4.684. Setiap citra memiliki resolusi yang cukup tinggi dan dilengkapi dengan nama folder sebagai label kelas, yang memudahkan proses segmentasi data berdasarkan kategori penyakit. File dikemas dalam struktur direktori yang memisahkan masing-masing kelas, sehingga proses pelabelan otomatis dapat diterapkan saat dilakukan pemuatan data ke dalam pipeline pelatihan. Tahapan pengumpulan data mencakup: unduhan dataset dalam format .zip, ekstraksi dataset ke struktur direktori lokal dan verifikasi visual untuk memastikan bahwa setiap citra mencerminkan label penyakit yang benar.

B. Pra-pemrosesan Data

Preprocessing Data merupakan tahapan penting dalam pengolahan citra digital untuk meningkatkan kualitas dan keseragaman data sebelum digunakan dalam pelatihan model *deep learning*. Adapun proses pra-pemrosesan yang telah dilakukan meliputi:

1. Penyesuaian Ukuran Gambar

Pada tahap penyesuaian ukuran gambar, seluruh citra yang semula memiliki resolusi heterogen dinormalisasi dimensinya menjadi 224×224 piksel agar selaras dengan spesifikasi input umum pada beragam arsitektur *Convolutional Neural Network* (CNN), termasuk *MobileNet* dan *ResNet*. Proses penskalaan ini diimplementasikan menggunakan pustaka *Python* bersama modul *TensorFlow* Image untuk memastikan konsistensi *pipeline* dan reproduksibilitas eksperimen. Selama transformasi, dipertimbangkan pula pemeliharaan rasio aspek melalui operasi seperti *cropping* terpusat atau penambahan padding bila diperlukan, sehingga distorsi bentuk objek dapat diminimalkan. Pemilihan ukuran 224×224 bertujuan menyederhanakan beban komputasi.

2. Split Dataset.

Untuk memastikan proses pengembangan dan evaluasi model berlangsung secara sistematis serta bebas bias, dataset pada penelitian ini dipartisi menjadi tiga subset utama, yakni data pelatihan (80%), data validasi (10%), dan data uji (10%). Pemisahan dilakukan secara acak dengan teknik *stratified split* sehingga distribusi proporsi kelas pada setiap subset tetap seimbang; pendekatan ini penting untuk mencegah dominasi kelas tertentu serta menjaga keterwakilan karakteristik data di seluruh tahap pemodelan. Subset pelatihan dimanfaatkan untuk mempelajari parameter model, sementara subset validasi digunakan dalam pemilihan arsitektur dan penyetelan hiperparameter guna mengurangi risiko *overfitting*. Adapun kinerja akhir model diukur menggunakan subset uji yang sepenuhnya tidak terlibat pada proses pelatihan maupun penyetelan, sehingga estimasi performa yang dihasilkan merefleksikan kemampuan generalisasi model pada data yang belum pernah dilihat sebelumnya.

C. Pembuatan dan Pelatihan Model

Untuk mendeteksi penyakit daun tanaman padi secara otomatis, penelitian ini mencoba membangun sebuah model *Convolutional Neural Network* (CNN) sederhana menggunakan *framework TensorFlow* dan *Keras*. Model ini dirancang dengan mempertimbangkan tiga kelas *output* (*NUM_CLASSES* = 3) yang merepresentasikan jenis penyakit daun padi yang berbeda. Citra masukan diatur dalam dimensi 224x224 piksel dengan tiga saluran warna RGB, yang secara umum telah terbukti efektif sebagai ukuran standar dalam berbagai studi pengenalan citra.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 224, 224, 32)	896
max_pooling2d (MaxPooling2D)	(None, 112, 112, 32)	0
dropout (Dropout)	(None, 112, 112, 32)	0
conv2d_1 (Conv2D)	(None, 112, 112, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 56, 56, 64)	0
dropout_1 (Dropout)	(None, 56, 56, 64)	0
conv2d_2 (Conv2D)	(None, 56, 56, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 28, 28, 128)	0
dropout_2 (Dropout)	(None, 28, 28, 128)	0
flatten (Flatten)	(None, 100352)	0
dense (Dense)	(None, 256)	25,690,368
dropout_3 (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 3)	771

Total params: 25,784,387 (98.36 MB)
 Trainable params: 25,784,387 (98.36 MB)
 Non-trainable params: 0 (0.00 B)

Gambar 2. Arsitektur CNN Deteksi Penyakit Daun Padi

Secara keseluruhan, model ini memiliki total 25.784.387 parameter, seluruhnya merupakan parameter yang dapat dilatih (*trainable*). Jumlah ini mencerminkan kompleksitas model yang cukup tinggi, terutama pada lapisan dense pertama yang menghubungkan fitur hasil konvolusi ke proses klasifikasi.

Arsitektur CNN dibangun secara bertahap melalui tiga blok konvolusi. Masing-masing blok terdiri atas lapisan Conv2D dengan kernel berukuran 3x3 dan fungsi aktivasi *ReLU*, diikuti dengan *MaxPooling2D* untuk mereduksi dimensi spasial dan *Dropout* untuk mengurangi *overfitting*. Jumlah filter bertambah secara progresif di setiap blok (32, 64, dan 128 *filter*), yang memungkinkan model menangkap fitur yang semakin kompleks. Setelah proses ekstraksi fitur, lapisan *Flatten* digunakan untuk mengubah data multidimensi menjadi satu dimensi, kemudian dilanjutkan dengan lapisan *Dense* sebanyak dua buah. Lapisan pertama memiliki 256 neuron dengan aktivasi *ReLU*, sedangkan lapisan terakhir menggunakan fungsi aktivasi *softmax* untuk klasifikasi multi-kelas.

Model dikompilasi menggunakan optimizer *Adam* dengan laju pembelajaran awal sebesar 0.001 (*learning rate*), dan menggunakan fungsi kerugian *categorical_crossentropy* yang sesuai untuk klasifikasi dengan label yang telah di *encode* secara *one-hot*. Selain itu, metrik yang dipantau selama pelatihan adalah akurasi (*accuracy*).

Untuk mengoptimalkan proses pelatihan dan menghindari *overfitting*, tiga teknik *callback* diterapkan dalam penelitian ini, diantaranya:

1. *EarlyStopping*, yang menghentikan pelatihan lebih awal jika *val_loss* tidak mengalami peningkatan dalam 6 *epoch*, serta mengembalikan bobot terbaik;
2. *ReduceLROnPlateau*, yang akan menurunkan *learning rate* sebesar setengahnya jika *val_loss* tidak membaik dalam 3 *epoch* berturut-turut;
3. *ModelCheckpoint*, yang menyimpan bobot model terbaik berdasarkan *val_accuracy* ke dalam file dengan ekstensi .h5.

Pelatihan model dilakukan dengan memanfaatkan data latih dan validasi selama 20 epoch. Selama proses ini, sistem secara otomatis menyesuaikan parameter-parameter pelatihan berdasarkan umpan balik dari data validasi. Hasil pelatihan model CNN divisualisasikan melalui grafik yang menunjukkan perkembangan metrik *accuracy* dan *loss* pada data pelatihan dan validasi selama 20 epoch. Grafik sebelah kiri menggambarkan kurva *Training Accuracy* dan *Validation Accuracy*, sedangkan grafik sebelah kanan menunjukkan *Training Loss* dan *Validation Loss*.



Gambar 3. Grafik Histori Epoch (20) Model CNN

Dari grafik *accuracy*, terlihat bahwa performa model mengalami peningkatan yang konsisten sejak awal pelatihan. Akurasi validasi meningkat tajam dari sekitar 0.52 pada epoch pertama hingga mencapai puncaknya di atas 0.99 pada epoch ke-19. Hal ini menunjukkan bahwa model mampu mempelajari fitur-fitur penting dari data dengan sangat baik. Kurva akurasi pelatihan juga menunjukkan tren yang sejalan, yang mencerminkan konvergensi model secara stabil tanpa gejala *overfitting* yang signifikan. Pada grafik *loss*, terlihat penurunan nilai kerugian (*loss*) baik pada data pelatihan maupun validasi. Nilai *training loss* turun dari lebih dari 1.0 menjadi mendekati 0.1, sementara *validation loss* menunjukkan penurunan yang lebih drastis hingga mendekati nol. Hal ini menunjukkan bahwa kesalahan prediksi model semakin kecil seiring berjalannya proses pelatihan.

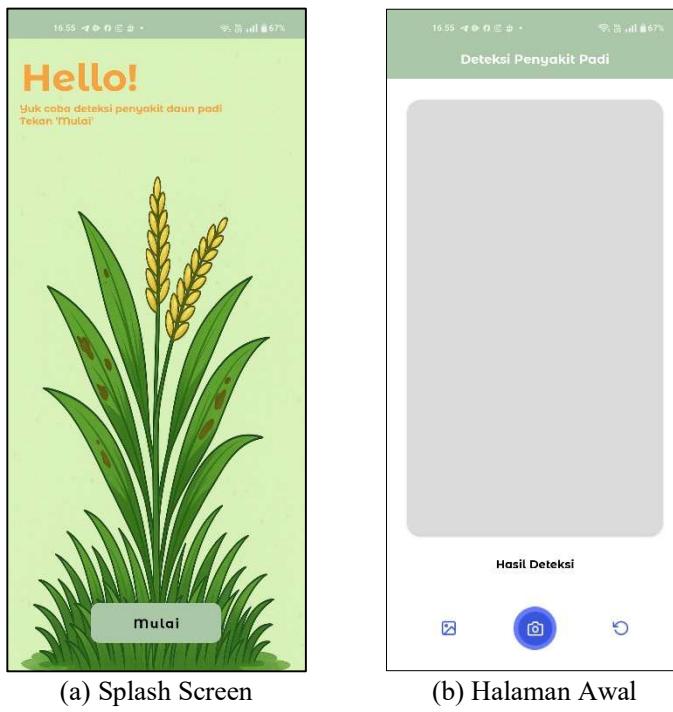
Secara keseluruhan, model CNN yang dibangun menunjukkan performa klasifikasi yang sangat baik, dengan akurasi validasi akhir sebesar 99.72% dan akurasi train sebesar 96.28%. Kinerja ini mengindikasikan bahwa model telah berhasil mempelajari representasi visual dari citra daun padi dengan optimal. Keseimbangan antara kurva pelatihan dan validasi juga menandakan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya.

D. Optimasi Model dengan *TensorFlow Lite*

Model Keras dikonversi ke *TensorFlow Lite* presisi *float32* menggunakan konverter resmi tanpa kuantisasi pasca pelatihan, sehingga bobot dan aktivasi tetap dalam *float32*. Artefak mengekspos satu signature dengan masukan $1 \times 224 \times 224 \times 3$ (*float32*) dan keluaran 1×3 beraktivasi *softmax*. Inferensi pada Android menggunakan *TFLite Interpreter* di CPU, dengan opsi delegasi NNAPI/GPU; meski berdampak pada ukuran model dan beban komputasi lebih besar dibandingkan *int8*, pendekatan ini mempertahankan perilaku numerik model asal dan akurasi yang stabil.

E. Pengembangan Aplikasi Android

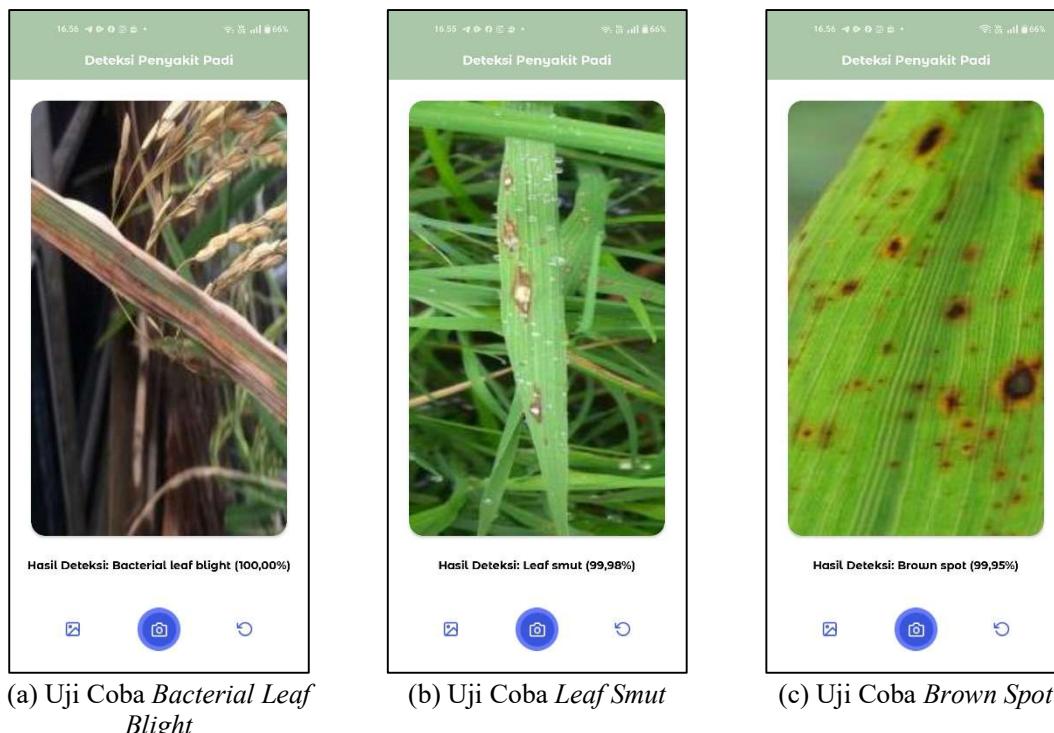
Aplikasi Android yang dikembangkan bertujuan untuk mendeteksi penyakit pada daun tanaman padi berdasarkan citra digital. Antarmuka aplikasi dirancang secara sederhana dan ramah pengguna. Terdapat beberapa komponen utama dalam alur kerja aplikasi, di antaranya:



Gambar 4. Implementasi Android - Halaman Awal

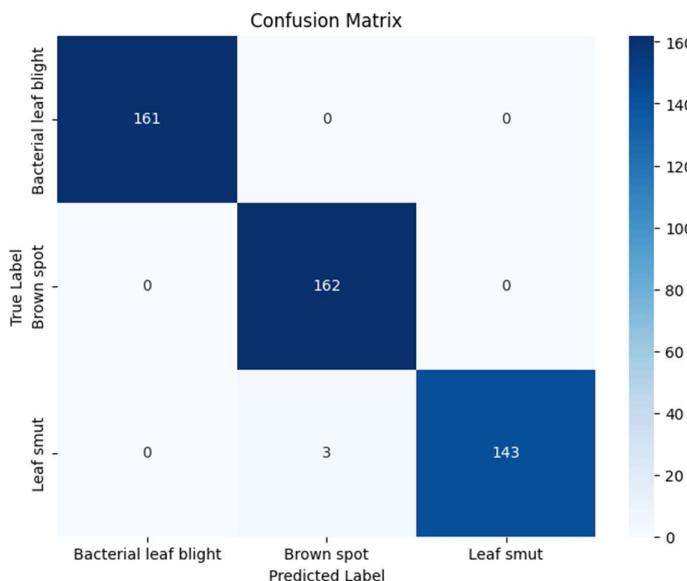
Aplikasi diawali dengan layar pengenalan yang menampilkan ilustrasi tanaman padi beserta ajakan interaktif untuk memulai proses deteksi melalui tombol “Mulai” (Gambar 4.a), setelah tombol tersebut di klik, pengguna diarahkan ke halaman deteksi utama yang menyediakan antarmuka akuisisi citra melalui tombol kamera dan galeri, sehingga sampel daun padi dapat diperoleh baik dengan pengambilan gambar langsung maupun pemilihan berkas dari penyimpanan perangkat guna mendukung proses inferensi model (Gambar 4.b). Pada tahap berikutnya, citra yang dipilih diproses oleh model .tflite yang tertanam di aplikasi, yang menghasilkan prediksi berupa label penyakit serta tingkat probabilitas (*persentase confidence*). Citra yang telah dianalisis kemudian ditampilkan kembali bersama keluaran deteksinya untuk mendukung interpretasi hasil oleh pengguna.

Antarmuka hasil deteksi menyajikan informasi secara ringkas dan mudah dipahami dengan menampilkan citra yang diuji beserta label penyakit secara *real-time*, sehingga memfasilitasi interpretasi diagnosis oleh petani maupun pengguna awam. Implementasi ini menunjukkan bahwa model CNN terlatih tidak hanya unggul secara empiris dengan akurasi pengujian keseluruhan mencapai 99%, tetapi juga layak diterapkan secara praktis dalam aplikasi *mobile* yang ringan dan responsif. Pada pengujian berbasis citra penyakit daun padi, sistem secara konsisten mengenali tiga kelas penyakit utama, yaitu *Bacterial leaf blight* dengan akurasi 100% (Gambar 5.a), *Leaf smut* dengan akurasi 99,98% (Gambar 5.b), dan *Brown spot* dengan akurasi 99,95% (Gambar 5.c). Temuan ini menegaskan potensi aplikasi sebagai alat bantu diagnosis awal yang andal untuk mendukung pengambilan keputusan pengendalian penyakit padi secara cepat dan tepat di lapangan.

**Gambar 5.** Implementasi Android - Uji Coba Deteksi Citra Penyakit Daun Padi

F. Evaluasi Kinerja

Untuk mengukur performa model CNN secara objektif terhadap data yang belum pernah dilihat sebelumnya (*unseen data*), dilakukan pengujian menggunakan data uji (*testing set*) yang terpisah dari proses pelatihan dan validasi. Pengujian dilakukan melalui *Google Colab* dan uji coba langsung melalui aplikasi Android yang telah dibangun. Hasil pengujian antara *Google Colab* dan Aplikasi yang telah dibangun memperoleh hasil prediksi yang sama. Hasil pengujian divisualisasikan dalam bentuk *confusion matrix* dan diperkuat dengan metrik evaluasi melalui *classification report*.

**Gambar 6.** Confusion Matrix Hasil Pengujian Data

Berdasarkan analisis *confusion matrix*, model menunjukkan kinerja klasifikasi yang sangat baik pada ketiga kelas penyakit daun padi: seluruh 161 citra *Bacterial leaf blight* dan 162 citra

Brown spot terkласifikasi dengan benar (akurasi per kelas 100%), sementara pada kelas *Leaf smut* sebanyak 143 dari 146 citra teridentifikasi tepat dan tiga citra keliru diprediksi sebagai *Brown spot*. Temuan ini selaras dengan *classification report* yang mencatat precision 1,00 untuk *Bacterial leaf blight* dan *Leaf smut* (dengan precision *Brown spot* sedikit lebih rendah, 0,98, akibat sebagian kecil prediksi salah arah), recall 1,00 pada *Bacterial leaf blight* dan *Brown spot* serta 0,98 pada *Leaf smut*, serta *F1-score* yang sangat tinggi dengan rata-rata 0,99, menandakan keseimbangan ketepatan dan kelengkapan yang optimal. Secara agregat, akurasi total pada data uji mencapai 99% (0,99), dan nilai macro average maupun weighted average untuk *precision*, *recall*, dan *F1-score* mengindikasikan konsistensi performa di seluruh kelas tanpa dominasi tertentu, sehingga meminimalkan bias klasifikasi. Dengan demikian, model CNN yang diusulkan efektif dan andal untuk deteksi penyakit daun padi berbasis citra digital, serta memiliki kesiapan kuat untuk diimplementasikan pada sistem *mobile* Android menggunakan *TensorFlow Lite*.

Tabel 1. Classification Report Data Uji

	Precision	Recall	F1-Score	Support
Bacterial leaf blight	1.00	1.00	1.00	161
Brown spot	0.98	1.00	0.99	162
Leaf smut	1.00	0.98	0.99	146
Accuracy			0.99	469
Macro avg	0.99	0.99	0.99	469
Weighted avg	0.99	0.99	0.99	469

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil menjawab permasalahan inefisiensi dan subjektivitas dalam identifikasi penyakit daun padi konvensional dengan mengembangkan sistem deteksi otomatis berbasis CNN yang dioptimalkan melalui *TensorFlow Lite*. Berdasarkan hasil eksperimen, model yang dikembangkan terbukti mampu mengklasifikasikan tiga penyakit utama *Bacterial Leaf Blight*, *Brown Spot*, dan *Leaf Smut* dengan akurasi pengujian mencapai 99%, serta berhasil diimplementasikan pada perangkat Android dengan performa yang stabil. Kemampuan aplikasi untuk melakukan diagnosis secara *offline* dan *real-time* di lapangan menegaskan bahwa sistem ini efektif sebagai solusi portabel dan objektif untuk mendukung petani dalam menanganiancaman penyakit padi secara lebih dini dan presisi.

5. DAFTAR PUSTAKA

- [1] S. Agustiani, Y. T. Arifin, A. Junaidi, S. K. Wildah, and A. Mustopa, “Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram,” *Jurnal Komputasi*, vol. 10, no. 1, pp. 65–74, Apr. 2022, doi: 10.23960/KOMPUTASI.V10I1.2961.
- [2] M. S. Nugroho and E. Nurraharjo, “Klasifikasi Hama Tanaman Padi berdasarkan Citra Daun Menggunakan Metode Convolutional Neural Network,” *BIOEDUSAINS:Jurnal Pendidikan Biologi dan Sains*, vol. 6, no. 2, pp. 672–682, Dec. 2023, doi: 10.31539/bioedusains.v6i2.8080.
- [3] F. H. Hawari, F. Fadillah, M. R. Alviandi, and T. Arifin, “Klasifikasi Penyakit Tanaman Padi Menggunakan Algoritma CNN (Convolutional Neural Network),” *Jurnal Responsif: Riset Sains dan Informatika*, vol. 4, no. 2, pp. 184–189, Aug. 2022, doi: 10.51977/JTI.V4I2.856.
- [4] M. Khoiruddin, A. Junaidi, and W. A. Saputra, “Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network,” *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, vol. 2, no. 1, pp. 37–45, Feb. 2022, doi: 10.20895/DINDA.V2I1.341.
- [5] U. N. Oktaviana, R. Hendrawan, A. D. K. Annas, and G. W. Wicaksono, “Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101,” *Jurnal RESTI (Rekayasa*

Sistem dan Teknologi Informasi), vol. 5, no. 6, pp. 1216–1222, Dec. 2021, doi: 10.29207/RESTI.V5I6.3607.

- [6] A. P. Pranjaya, F. Rizki, R. Kurniawan, and N. K. Daulay, “Klasifikasi Penyakit Pada Daun Tanaman Padi Berbasis YoloV5 (You Only Look Once),” *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 4, no. 6, pp. 3127–3136, Jun. 2024, doi: 10.30865/KLIK.V4I6.1916.
- [7] I. Perlindungan and Risnawati, “Pengenalan Tanaman Cabai dengan Teknik Klasifikasi Menggunakan Metode CNN,” *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya*, vol. 1, no. 2, pp. 15–22, 2020, [Online]. Available: <https://conference.upnvj.ac.id/index.php/senamika/article/view/694>
- [8] R. A. A. Malik and Y. Sibaroni, “Multi-aspect Sentiment Analysis of TikTok Application Usage Using FasText Feature Expansion and CNN Method,” *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 4, pp. 277–285, Sep. 2022, doi: 10.47065/josyc.v3i4.2033.
- [9] S. K. Ladi, G. K. Panda, R. Dash, P. K. Ladi, and R. Dhupar, “A Novel Grey Wolf Optimisation based CNN Classifier for Hyperspectral Image classification,” *Multimed Tools Appl*, vol. 81, no. 20, pp. 28207–28230, 2022, doi: 10.1007/S11042-022-12628-2/METRICS.
- [10] S. P. Mohanty, D. P. Hughes, and M. Salathé, “Using deep learning for image-based plant disease detection,” *Front Plant Sci*, vol. 7, no. September, Sep. 2016, doi: 10.3389/FPLS.2016.01419.,
- [11] K. P. Ferentinos, “Deep learning models for plant disease detection and diagnosis,” *Comput Electron Agric*, vol. 145, pp. 311–318, Feb. 2018, doi: 10.1016/J.COMPAG.2018.01.009.
- [12] O. V. Putra, M. Z. Mustaqim, and D. Muriatmoko, “Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2,” *Techno.Com*, vol. 22, no. 3, pp. 562–575, Aug. 2023, doi: 10.33633/TC.V22I3.8516.
- [13] R. Muslim, Z. Zaeniah, A. Akbar, B. Imran, and Z. Zaenudin, “Disease Detection of Rice and Chili Based on Image Classification Using Convolutional Neural Network Android-Based,” *Jurnal Pilar Nusa Mandiri*, vol. 19, no. 2, pp. 85–96, Sep. 2023, doi: 10.33480/PILAR.V19I2.4669.
- [14] H. F. Pardede, E. Suryawati, D. Krisnandi, R. S. Yuwana, and V. Zilvan, “Machine Learning Based Plant Diseases Detection: A Review,” *Proceeding - 2020 International Conference on Radar, Antenna, Microwave, Electronics and Telecommunications, ICRA MET 2020*, pp. 212–217, Nov. 2020, doi: 10.1109/ICRAMET51080.2020.9298619.
- [15] J. Dev, “Rice Plant diseases dataset,” 2024, *Kaggle*. doi: 10.34740/KAGGLE/DSV/8291958.