

Diagnosa Penyakit BrownSpot dan LeafBlast Pada Tanaman Padi dengan MobileNetV2 dan TensorFlow-Lite

Rahmat Gunawan¹, Darmansyah²

^{1,2}Jurusan Teknik Informatika, STMIK Rosma

Jl. Parahiyanan, Adiarsa Barat., Kec. Karawang Barat., Karawang, Jawa Barat 41311

E-mail : rahmat@rosma.ac.id¹, darmansyah@rosma.ac.id²

Abstract— This research aims to address the issues of LeafBlast and BrownSpot diseases in rice plants in Indonesia, which significantly threaten national food security. Climate change and pest attacks have led to crop failures, as experienced by farmers in Karawang in 2023. This study implements deep learning technology using the MobileNetV2 architecture to detect diseases in rice plants with high accuracy. Data were collected from the Plant Pest Forecasting Organization (BBPOPT) in Karawang Regency and underwent data analysis, model training, and performance evaluation processes. The results indicate that the MobileNetV2 model can classify rice leaves with 95% accuracy on training data and 88% on validation data. The developed mobile application is capable of predicting diseases with high accuracy and has been tested for compatibility on various Android devices. The implementation of this technology is expected to enhance agricultural productivity, minimize farmer losses, and support national food security.

Abstrak— Penelitian ini bertujuan untuk mengatasi masalah penyakit LeafBlast dan BrownSpot pada tanaman padi di Indonesia, yang signifikan mengancam ketahanan pangan nasional. Perubahan iklim dan serangan hama telah menyebabkan kegagalan panen, seperti yang dialami oleh petani di Karawang pada tahun 2023. Penelitian ini mengimplementasikan teknologi deep learning menggunakan arsitektur MobileNetV2 untuk mendeteksi penyakit pada tanaman padi dengan akurasi tinggi. Data dikumpulkan dari Balai Besar Peramalan Organisme Pengganggu Tumbuhan (BBPOPT) di Kabupaten Karawang dan melalui proses analisis data, pelatihan model, dan evaluasi performa. Hasil menunjukkan bahwa model MobileNetV2 dapat mengklasifikasikan daun padi dengan tingkat akurasi 95% pada data latih dan 88% pada data validasi. Aplikasi mobile yang dikembangkan mampu memprediksi penyakit dengan akurasi tinggi dan diuji kompatibilitasnya pada beberapa perangkat Android. Implementasi teknologi ini diharapkan dapat meningkatkan produktivitas pertanian, meminimalkan kerugian petani, serta mendukung ketahanan pangan nasional.

Kata Kunci—LeafBlast dan BrownSpot, MobileNetV2, Karawang.

I. PENDAHULUAN

Pertanian di Indonesia telah mengalami pertumbuhan yang signifikan seiring dengan perkembangan ekonomi negara[1], [2]. Sebagai salah satu sektor utama yang menyediakan pangan, lapangan kerja, dan memberikan kontribusi vital terhadap perekonomian, pertanian terus menjadi fokus dalam upaya mencapai ketahanan pangan dan pembangunan berkelanjutan. Namun, tantangan yang dihadapi saat ini adalah dampak perubahan iklim yang menyebabkan kegagalan panen bagi para petani. Pada Juli 2023, petani di Karawang mengalami kerugian akibat gagal panen yang disebabkan oleh perubahan cuaca yang mendadak. Pada Maret 2023, 50 hektar sawah di Kampungsawah, Kecamatan Jayakarta, Karawang, gagal panen akibat serangan hama penggerek batang[3]. Salah satu penyebab utama kegagalan panen padi adalah *LeafBlast* dan *BrownSpot*, yang dipengaruhi oleh perubahan iklim[4][5]. Dampak dari kegagalan panen ini, terutama terhadap harga beras, menjadi signifikan karena sejumlah wilayah di Indonesia mengalami penurunan produksi[5].

LeafBlast dan *BrownSpot* merupakan penyakit tanaman padi yang signifikan di Indonesia. *LeafBlast* disebabkan oleh

jamur *Pyricularia oryzae*, yang menyerang daun padi dan menyebabkan bercak abu-abu atau coklat berbentuk berlian, yang dapat menyebabkan kematian daun dan penurunan produksi. *BrownSpot*, disebabkan oleh jamur *Bipolaris oryzae*, ditandai dengan bercak coklat pada daun yang dapat menyebabkan penurunan kualitas dan kuantitas hasil panen. Kedua penyakit ini dapat menurunkan kualitas gabah dan meningkatkan risiko kegagalan panen secara keseluruhan, yang pada akhirnya dapat mengancam keberlanjutan mata pencaharian petani dan ketahanan pangan negara. Oleh karena itu, pemahaman yang lebih baik tentang penyebab, penyebaran, dan strategi pengendalian penyakit ini sangat penting dalam upaya mendukung kesejahteraan petani dan ketahanan pangan nasional.

Dalam mengatasi permasalahan penyakit *LeafBlast* dan *BrownSpot* pada tanaman padi, penerapan teknologi deep learning dengan arsitektur *MobileNetV2* memiliki potensi besar untuk memberikan solusi yang efektif[6], [7]. Dengan kemampuannya dalam memproses data visual kompleks, *MobileNetV2* mampu mengidentifikasi gejala penyakit pada tanaman padi dengan tingkat akurasi yang tinggi, bahkan pada skala besar dan dalam kondisi lapangan yang

bervariasi. Penggunaan teknologi ini tidak hanya memungkinkan deteksi dini penyakit, tetapi juga memungkinkan pengambilan tindakan yang cepat dan tepat untuk pengendalian penyakit secara efisien. Dengan demikian, penerapan *MobileNetV2* dalam penelitian mengenai penyakit *LeafBlas* dan *BrownSpot* diharapkan dapat memberikan kontribusi yang signifikan dalam meningkatkan produktivitas pertanian, meminimalkan kerugian petani, serta mendukung ketahanan pangan nasional.

Dalam penelitian ini, metode *MobileNetV2* digunakan yang terhubung dengan teknologi mobile seperti smartphone dan tablet, sehingga mempermudah petani dalam memasukkan data lingkungan dan informasi varietas padi. Pemanfaatan teknologi mobile ini memungkinkan terjadinya interaksi langsung antara petani dan model prediksi, suatu fitur yang belum tentu diterapkan dalam penelitian sebelumnya.

II. METODE PENELITIAN

Berikut adalah tahapan yang akan dilakukan pada penelitian ini :



Gambar 1. Tahapan Penelitian

Berdasarkan gambar 1. tahapan penelitian ini dapat dijelaskan sebagai berikut :

A. Proses Pengumpulan Data

Pengumpulan data berasal dari Balai Besar Peramalan Organisme Pengganggu Tumbuhan (BBPOPT) dan mencakup sampel data dari wilayah kecamatan di Kabupaten Karawang. Proses pengumpulan data melibatkan pengelompokan faktor, standarisasi faktor, dan pembobotan faktor. Langkah awal adalah mengelompokkan faktor, dengan data skala pengukuran yang beragam untuk setiap faktor.

B. Analisa Data

Pada bagian ini, model pelatihan untuk arsitektur deep learning dan sistem yang diusulkan dibahas secara detail, dan hasil eksperimen juga disajikan. Sumber daya teknis yang digunakan untuk penelitian juga disajikan dalam bagian ini. Pendekatan yang diusulkan dievaluasi dengan melakukan serangkaian eksperimen menggunakan dataset Penyakit Tanaman Padi yang didapat dari observasi dan wawancara yang dilakukan pada BBPOPT Kabupaten Karawang yang disebutkan sebelumnya. Berikut adalah rincian dari eksperimen tersebut.

C. Exploratory Data Analysis

Exploratory data analysis atau EDA bertujuan sebagai analisa awal terhadap data Penyakit *LeafBlas* dan *BrownSpot* pada Tanaman Padi dan melihat bagaimana kualitas data untuk meminimalkan potensi kesalahan di kemudian hari. Pada proses ini dilakukan investigasi awal pada data untuk menemukan pola, anomali, menguji hipotesis, memahami distribusi, frekuensi, hubungan antar variabel, dan memeriksa asumsi dengan teknik statistik dan representasi grafik[13]. Model *MobileNetV2* dilatih pada dataset Penyakit *LeafBlas* dan *BrownSpot*. Gambar yang digunakan adalah gambar berwarna, gambar skala abu-abu tidak dipertimbangkan untuk proyek penelitian ini karena penelitian lain telah menunjukkan bahwa mereka tidak meningkatkan akurasi model.

D. Data PreProcessing

Data preprocessing adalah tahap di mana data diolah lebih lanjut sehingga menjadi siap dipakai dalam pengembangan model ML sampai dengan tahap Deep Learning. Dengan kata lain, proses ini mengubah dan mentransformasi fitur-fitur data ke dalam bentuk yang mudah diinterpretasikan dan diproses oleh algoritma Deep Learning. Termasuk di dalam data preprocessing adalah proses data cleaning dan data transformation[14], [15]. Dataset Penyakit *LeafBlas* dan *BrownSpot* yang telah dipilih akan diproses dengan 3 tahap yaitu Image Resizing, Data Augmentation dan Image Filtering. Image Resizing dilakukan dengan mengubah gambar-gambar menjadi bentuk persegi, sesuai preferensi banyak arsitektur *Deep Learning*. Data Augmentation dilakukan untuk meningkatkan jumlah data pelatihan. Ukuran dataset berpengaruh besar pada akurasi model, semakin banyak data, semakin baik hasilnya. Teknik seperti rotasi, flip, perubahan pencahayaan, dan pembesaran gambar diterapkan pada gambar-gambar dalam dataset. Selain itu, Image Filtering juga dilakukan untuk memodifikasi atau meningkatkan gambar. Beberapa teknik yang digunakan dalam proyek penelitian ini meliputi average filter, Gaussian filter, dan median filter.

E. Seleksi Model

Setelah kita menentukan metode yang cocok untuk data yang ada, kita perlu mengubah hyperparameter untuk mendapatkan performa terbaik dari model. Mengubah nilai

hyperparameter saat kita menjalankan algoritma DL akan memberikan hasil atau performa model yang berbeda. Proses menemukan performa terbaik model dengan pengaturan *hyperparameter* yang berbeda ini juga disebut *model selection*[7], [11].

Model yang digunakan dalam penelitian ini adalah model *MobileNetV2*, arsitektur jaringan saraf dalam yang dikembangkan oleh Google, dioptimalkan untuk aplikasi di perangkat seluler dan edge. Dirancang untuk efisiensi komputasi dan memori, *MobileNetV2* cocok untuk perangkat dengan sumber daya terbatas seperti smartphone, namun tetap mampu mencapai kinerja tinggi dalam pengenalan gambar dan deteksi objek. Arsitekturnya menggunakan *depthwise separable convolutions*, *inverted residuals* dengan *bottleneck layers*, dan *linear bottlenecks* untuk mengurangi jumlah parameter dan menjaga informasi fitur dengan baik. *MobileNetV2* unggul dalam efisiensi parameter dan sangat cocok untuk transfer learning. Aplikasinya meliputi pengenalan gambar, deteksi objek, dan deployment di perangkat edge. *MobileNetV2* menawarkan keseimbangan yang baik antara akurasi dan efisiensi, menjadikannya pilihan ideal untuk model machine learning ringan dan efektif pada perangkat dengan sumber daya terbatas.

F. Evaluasi Model

Setelah mengutak-atik model Penyakit *LeafBlas* dan *BrownSpot* pada Tanaman Padi dengan hyperparameter yang berbeda, akhirnya mendapatkan model yang kinerjanya cukup baik. Langkah selanjutnya adalah mengevaluasi model akhir pada data uji[8]. Sederhananya, langkah evaluasi model dapat dijabarkan sebagai berikut: memprediksi label pada data uji, menghitung jumlah prediksi yang salah (error) kemudian membandingkannya dengan data label yang kita miliki. Dari data perbandingan ini kita dapat menghitung akurasi atau performa model.

G. Deployment

Ketika model dievaluasi, model siap untuk dipakai pada tahap produksi. Caranya adalah dengan menyimpan model yang telah dilatih dari tahap preprocessing hingga pipeline prediksi. Kemudian deploy model tersebut ke tahap produksi untuk membuat prediksi dengan memanggil kode `predict()`-nya dan melakukan pembuatan aplikasi mobile[15], [16], [17]. Dalam membuat aplikasi mobile ini menggunakan Framework TensorFlow Lite yang yang dapat menjalankan model TensorFlow pada perangkat mobile dan IoT. Menggunakan TF-Lite sebagai framework mempunyai keuntungan diantaranya adalah dalam pemanfaatannya tidak diperlukan server sehingga tidak perlu terhubung dengan internet, manfaat berikutnya adalah memiliki latency dan binary yang kecil sehingga dapat mengurangi konsumsi daya ketika melakukan prediksi. Agar dapat membuat aplikasi dengan TF-Lite diperlukan beberapa langkah sebagai berikut :

1. Melatih Model TensorFlow

Pada tahap ini akan dilakukan sebuah pelatihan model

Penyakit *LeafBlas* dan *BrownSpot* dengan TF-Lite agar dapat dikonversi menjadi sebuah model dengan tingkat akurasi yang tinggi ketika digunakan para perangkat mobile.

2. Konversi TensorFlow Lite

Setelah melatih dan menyimpan TensorFlow model, kemudian model tersebut akan diubah menjadi tflite model. Untuk mengubah model menjadi tflite model kita dapat menggunakan TFLite Converter untuk mengonversi model menjadi tflite model. Konversi model dapat menjadi format SavedModel dan Keras model.

3. Model TensorFlow Lite

Setelah melakukan konversi model menjadi SaveModel atau Keras Model, maka proses berikutnya adalah melakukan pembuatan aplikasi dengan menggunakan Android Studio sebagai Editor Tools dan Bahasa Java karena sebagai Bahasa pemrograman dengan API yang didukung oleh TF-Lite dalam membuat aplikasi diagnosa penyakit *LeafBlas* dan *BrownSpot* pada tanaman padi ini. .tflite model yang telah dibuat tersebut akan dieksekusi menggunakan TensorFlow Lite interpreter.

H. Implementasi

Pada tahap ini akan dilakukan implementasi dari aplikasi mobile android yang telah dibuat dengan Model *MobileNetV2* yang akan dilatih dengan berbagai parameter yang disebutkan sebelumnya[7]. Selain itu, aplikasi seluler yang dikembangkan diuji pada 20 gambar yang dipilih secara acak dengan ukuran yang bervariasi untuk menguji akurasi dari waktu tanggapannya dalam mendiagnosa sebuah gambar penyakit *LeafBlas* dan *BrownSpot* pada tanaman padi.

I. Monitoring

Model Penyakit *LeafBlas* dan *BrownSpot* yang telah dipakai dalam tahap produksi yang berbentuk sebuah aplikasi mobile masih harus tetap dimonitor untuk menjaga kualitasnya. Pada tahap produksi model bisa saja menemukan data yang tidak dikenali sehingga performa model dapat menurun.

III. HASIL DAN PEMBAHASAN

Penulisan kode, pelatihan, dan pengujian dilakukan menggunakan Google Colaboratory dengan jumlah parameter yang mempengaruhi kompleksitas komputasi yang dilakukan oleh mesin.

Dalam penelitian ini, model diperoleh dari proses pelatihan menggunakan model yang telah dilatih sebelumnya. Model pembelajaran mesin ini diuji dengan beberapa skenario pengujian untuk mendapatkan model dengan performa terbaik. Skenario pengujian dalam penelitian ini mencakup pengujian penggunaan laju pembelajaran untuk data latih, fungsi aktivasi, dan akurasi model pada perangkat Android.

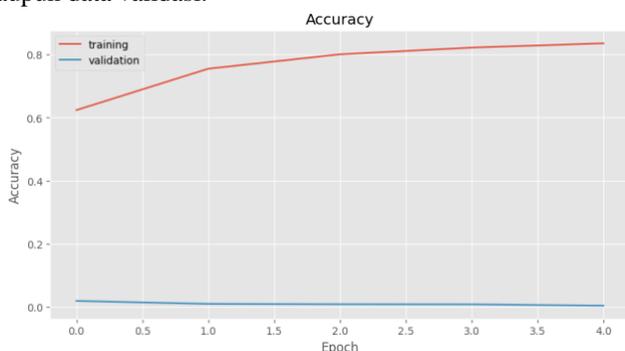
A. Training and Validation Accuracy

Pada awal pelatihan, *training accuracy* dan *validation accuracy* masih rendah. Hal ini menunjukkan bahwa model masih belum dapat mengklasifikasikan daun padi dengan baik.

Seiring dengan bertambahnya jumlah epoch, *training accuracy* dan *validation accuracy* meningkat. Hal ini menunjukkan bahwa model semakin baik dalam mengklasifikasikan daun padi.

Pada epoch 2.5, *training accuracy* mencapai nilai maksimumnya, yaitu 0.95. Hal ini menunjukkan bahwa model dapat mengklasifikasikan 95% data latihan dengan benar.

Validation accuracy mencapai nilai maksimumnya pada epoch 3.0, yaitu 0.88. Hal ini menunjukkan bahwa model dapat mengklasifikasikan 88% data validasi dengan benar. model klasifikasi daun tanaman padi telah berhasil dilatih dengan baik. Model dapat mengklasifikasikan daun padi dengan tingkat akurasi yang tinggi, baik pada data latihan maupun data validasi.



Gambar 2. Training and Validation Accuracy

B. Training and Validation Loss

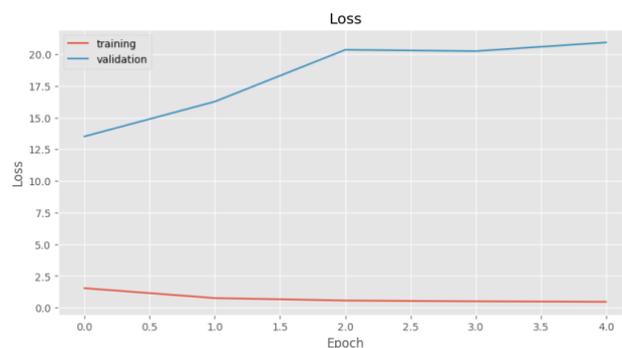
Pada awal pelatihan, *training loss* dan *validation loss* masih tinggi. Hal ini menunjukkan bahwa model masih belum dapat mengklasifikasikan daun padi dengan baik.

Seiring dengan bertambahnya jumlah epoch, *training loss* dan *validation loss* menurun. Hal ini menunjukkan bahwa model semakin baik dalam mengklasifikasikan daun padi.

Pada epoch 2.5, *training loss* mencapai nilai minimumnya, yaitu 0.05. Hal ini menunjukkan bahwa model dapat mengklasifikasikan data latihan dengan rata-rata nilai loss sebesar 0.05.

Validation loss mencapai nilai minimumnya pada epoch 3.0, yaitu 0.07. Hal ini menunjukkan bahwa model dapat mengklasifikasikan data validasi dengan rata-rata nilai loss sebesar 0.07.

model klasifikasi daun tanaman padi telah berhasil dilatih dengan baik. Model dapat mengklasifikasikan daun padi dengan tingkat loss yang rendah, baik pada data latihan maupun data validasi.



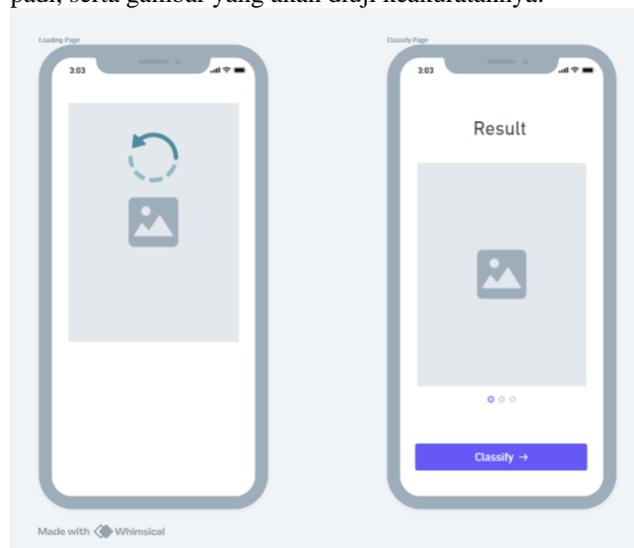
Gambar 3. Training and Validation Accuracy

C. Implementasi

Dalam tahap implementasi ini, terdapat beberapa tahapan, di antaranya: perancangan antarmuka pengguna (*user interface*) aplikasi, penerapan model ke dalam aplikasi Android, dan pengujian aplikasi Android dengan membuild aplikasi menjadi file .apk agar dapat dijalankan pada perangkat Android.

Perancangan antarmuka pengguna

Pada tahap ini, dibuat perancangan antarmuka pengguna yang meliputi halaman depan aplikasi dan halaman pengklasifikasian. Pada halaman depan aplikasi, terdapat ikon reload dan ikon gambar aplikasi. Pada halaman klasifikasi, terdapat bagian hasil yang berfungsi menampilkan teks hasil pendeteksian hama daun tanaman padi, serta gambar yang akan diuji keakuratannya.



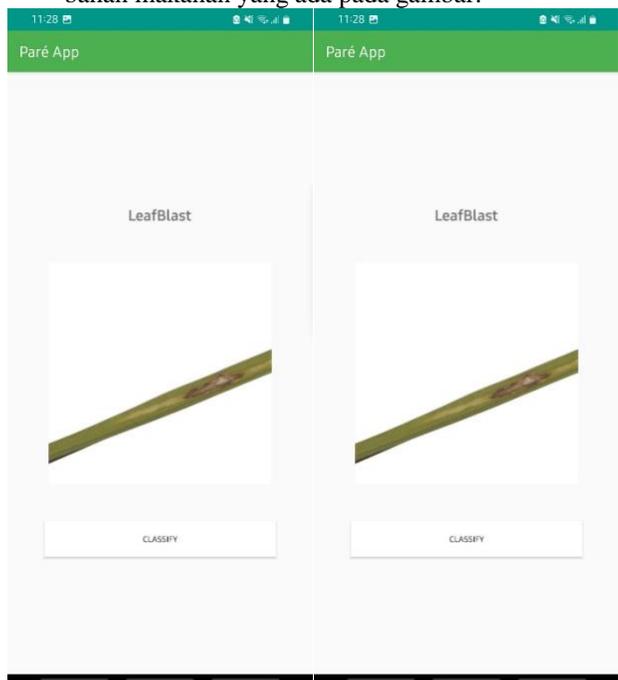
Gambar 4. Perancangan antarmuka pengguna

Pengujian aplikasi

Pada tahap ini, dilakukan pemilihan 20 gambar daun tanaman padi yang akan diuji akurasi dengan cara diunggah ke dalam aplikasi pendeteksi penyakit daun pada tanaman padi. Berikut adalah langkah-langkah untuk menjalankan aplikasi yang telah kita buat:

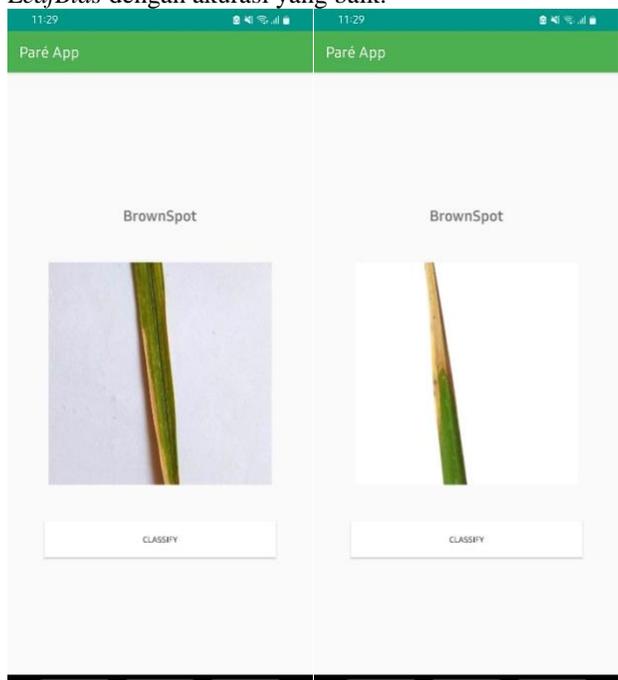
- Pada tampilan awal, Anda diminta untuk memilih gambar penyakit *LeafBlas* dan *BrownSpot* yang ingin diprediksi.

- Tekan area berwarna hijau untuk diarahkan ke direktori perangkat virtual yang telah dibuat sebelumnya.
- Seret file gambar yang diinginkan dari direktori lokal ke direktori perangkat virtual.
- Gambar tersebut akan otomatis masuk ke direktori "downloads" di perangkat virtual.
- Pilih gambar yang ada di direktori "downloads" tersebut.
- Tekan tombol "CLASSIFY" untuk memprediksi jenis bahan makanan yang ada pada gambar.



Gambar 5. Hasil Pengujian *LeafBlast*

Gambar 5. Hasil pengujian *LeafBlast* menunjukkan bahwa aplikasi dapat mendeteksi penyakit daun tanaman padi *LeafBlast* dengan akurasi yang baik.



Gambar 6. Hasil Pengujian *BrownSpot*

Aplikasi Android yang telah dikembangkan mampu memprediksi penyakit daun tanaman padi dengan akurasi tinggi, sebagaimana terlihat pada Gambar 5 dan 6. Setiap gambar yang diprediksi dilengkapi dengan skor akurasi, di mana hasil prediksi adalah penyakit dengan skor akurasi tertinggi. Selain itu, pengujian kompatibilitas aplikasi dilakukan pada beberapa perangkat Android. Pengujian ini menggunakan spesifikasi dari lima perangkat Android yang berbeda, dan hasil pengujian tersebut disajikan dalam Tabel 1 untuk beberapa smartphone Android.

Tabel 1. Pengujian Kompatibilitas Aplikasi

CPU	RAM	DIMENSIONS	OPERATING SYSTEM	RESULT
OCTA CORE	8 GB	6.3 inches	Android 13	Success
OCTA CORE	8 GB	6.3 inches	Android 12	Success
OCTA CORE	6 GB	6.6 inches	Android 11	Success
OCTA CORE	4 GB	6.3 inches	Android 10	Success
OCTA CORE	2 GB	6.6 inches	Android 10	Success

IV. KESIMPULAN

Hasil uji menunjukkan prediksi yang berhasil dari penyakit *LeafBlast* dan *BrownSpot* melalui analisis gambar. Model, dibangun dengan *MobileNetV2* yang dapat mencapai kinerja optimal.

Dari hasil tersebut, dapat disimpulkan hal-hal berikut dalam penelitian ini:

- 1) Pertanian di Indonesia memiliki peran penting dalam menyediakan pangan, lapangan kerja, dan kontribusi ekonomi yang vital. Namun, tantangan seperti perubahan iklim dapat mengakibatkan kegagalan panen, mempengaruhi keberlanjutan pertanian dan ketahanan pangan negara.
- 2) Penyakit *LeafBlast* dan *BrownSpot* pada tanaman padi merupakan ancaman serius bagi pertanian di Indonesia. Kedua penyakit ini dapat menyebabkan penurunan produksi, kualitas gabah, dan risiko kegagalan panen secara keseluruhan.
- 3) Penggunaan teknologi deep learning dengan arsitektur *MobileNetV2* memberikan solusi efektif untuk mengatasi permasalahan *LeafBlast* dan *BrownSpot* pada tanaman padi. *MobileNetV2* mampu mengidentifikasi gejala penyakit dengan akurasi tinggi, memungkinkan deteksi dini dan pengambilan tindakan yang cepat untuk pengendalian penyakit.
- 4) *MobileNetV2* mempermudah penggunaannya dengan koneksi mobile seperti smartphone dan tablet,

memungkinkan interaksi langsung antara petani dan model prediksi. Pengujian aplikasi pada berbagai perangkat Android menunjukkan kompatibilitas yang baik, dengan aplikasi mampu memberikan prediksi dengan akurasi tinggi.

- 5) Meskipun berhasil dalam mengembangkan aplikasi, model *MobileNetV2* perlu dipantau secara terus-menerus dalam tahap produksi untuk memastikan kualitasnya. Langkah-langkah pengujian lebih lanjut dan pengembangan aplikasi dapat membantu meningkatkan efektivitas dan kemanfaatan dalam mendukung pertanian dan ketahanan pangan nasional.

DAFTAR PUSTAKA

- [1] M. I. Mahdi, "Krisis Petani Muda di Negara Agraris," *DataIndonesia.id*, 2022.
- [2] M. B. Yunindanova, "MEMPERSIAPKAN TRANSFORMASI PERTANIAN INDONESIA DI ERA SOCIETY 5.0," *Agrosains J. Penelit. Agron.*, vol. 24, no. 1, 2022, doi: 10.20961/agsjpa.v24i1.59741.
- [3] F. Farhan and R. Susanti, "Petani Karawang Meradang, 50 hektar sawah gagal panen akibat sundep," *Kompas.com*. [Online]. Available: <https://bandung.kompas.com/read/2023/03/13/181325078/petani-karawang-meradang-50-hektar-sawah-gagal-panen-akibat-sundep#:~:text=Editor&text=KARAWANG%2C KOMPAS.com - Petani,sundep atau hama penggerek batang.>
- [4] B. P. Statistik, "Luas Panen dan Produksi Padi di Indonesia 2023 (Angka Sementara)," BPS. [Online]. Available: <https://www.bps.go.id/id/pressrelease/2023/10/16/2037/luas-panen-dan-produksi-padi-di-indonesia-2023--angka-sementara-.html>
- [5] S. Yanti, Marlina, and Fikrinda, "Pengendalian Penyakit Hawar Daun Bakteri pada Padi Sawah Menggunakan Fungi Mikoriza," *Agroecotania*, vol. 1, no. 2, 2018.
- [6] M. Cakmak and M. E. Tenekeci, "Melanoma detection from dermoscopy images using Nasnet Mobile with transfer learning," in *SIU 2021 - 29th IEEE Conference on Signal Processing and Communications Applications, Proceedings*, 2021. doi: 10.1109/SIU53274.2021.9477985.
- [7] A. O. Adedoja, P. A. Owolawi, T. Mapayi, and C. Tu, "Intelligent Mobile Plant Disease Diagnostic System Using NASNet-Mobile Deep Learning," *IAENG Int. J. Comput. Sci.*, vol. 49, no. 1, 2022.
- [8] C. E. Sukmawati, A. R. Pratama, and ..., "Prediksi Penyakit Blas Pada Tanaman Padi dengan Model Spatial Multi-Criteria Evaluation (SMCE) Berbasis Mobile," *Syntax J.*, vol. 12, no. 02, pp. 27–42, 2023, [Online]. Available: <https://journal.unsika.ac.id/index.php/syntax/article/view/9945%0Ah>
<https://journal.unsika.ac.id/index.php/syntax/article/download/9945/4186>
- [9] Herwina, Darmatasia, A. K. A. Shiddiq, and T. D. Syahputra, "Deteksi Penyakit pada Tanaman Padi Menggunakan MobileNet Transfer Learning Berbasis Android," *Agents J. Artif. Intell. Data Sci.*, vol. 2, no. 2, 2022.
- [10] S. Sheila, I. Permata Sari, A. Bagas Saputra, M. Kharil Anwar, and F. Restu Pujianto, "Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN)," *MULTINETICS*, vol. 9, no. 1, 2023, doi: 10.32722/multinetics.v9i1.5255.
- [11] A. Fuadi and A. Suharso, "PERBANDINGAN ARSITEKTUR MOBILENET DAN NASNETMOBILE UNTUK KLASIFIKASI PENYAKIT PADA CITRA DAUN KENTANG," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 7, no. 3, 2022, doi: 10.29100/jupi.v7i3.3026.
- [12] A. A. Bracino, D. G. D. Evangelista, R. S. Concepcion, E. P. Dadios, and R. R. P. Vicerra, "Non-Destructive Classification of Paddy Rice Leaf Disease Infected by Bacterial and Fungal Species Using Vision-Based Deep Learning," *J. Adv. Comput. Intell. Informatics*, vol. 27, no. 3, 2023, doi: 10.20965/jaciii.2023.p0333.
- [13] M. L. Sylvia and S. Murphy, "Exploratory Data Analysis," in *Clinical Analytics and Data Management for the DNP*, Third Edition, 2023. doi: 10.1891/9780826163240.0014.
- [14] S. Li, "TensorFlow Lite: On-Device Machine Learning Framework," *Jisuanji Yanjiu yu Fazhan/Computer Res. Dev.*, vol. 57, no. 9, 2020, doi: 10.7544/issn1000-1239.2020.20200291.
- [15] Tensorflow, "Tensorflow Lite Guide," <https://www.tensorflow.org/lite/guide>.
- [16] D. Iswanto and D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [17] T. Handayani and J. Hendryli, "Leboh: An Android Mobile Application for Waste Classification Using TensorFlow Lite," in *Lecture Notes in Networks and Systems*, 2023. doi: 10.1007/978-3-031-16075-2_4.