Jurnal Teliska
Volume 19 No.3 November 2026
Doi: 10.36257/teliska.v19i3.12717

P-ISSN: 2085-0786
E-ISSN: 2654-2765

IMPLEMENTASI AI FRUIT SCANNER UNTUK KLASIFIKASI KEMATANGAN PISANG MENGGUNAKAN MOBILENETV2

Herdianto Hamzah[1], Mohammad Lutfi[2], Pradipa Rasendriyantho[3], Rachmat Adi Purnama[4], Sujiliani Heristian[5], Veti Apriana[6],

Program Studi Teknik Informatika, Universitas Bina Sarana Informatika, Jakarta, Indonesia[1-4]
Program Studi Teknologi Komputer, Universitas Bina Sarana Informatika, Jakarta, Indonesia[5]
Program Studi Teknik Industri, Universitas Bina Sarana Informatika, Jakarta, Indonesia[6]
herdiantohamzah5@gmail.com

Submitted: 4 November 2026 | **Accepted**: 17 November 2026 | **Published**: 20 November 2026

ABSTRAK

Pada perkebunan pisang berskala luas, memeriksa buah pohon demi pohon untuk menilai kesiapannya menyita banyak waktu dan tenaga. Untuk meringankan pekerjaan itu, penelitian ini membangun AI Fruit Scanner, aplikasi berbasis kecerdasan buatan yang menilai kondisi pisang dari gambar dan menempatkannya pada salah satu dari tiga kelas: *Unripe* (mentah), *Ripe* (matang), atau *Rotten* (busuk). Modelnya dibangun dengan *transfer learning* berbasis MobileNetV2. Data berupa 1.497 citra, yaitu 499 per kelas setelah diseimbangkan, dengan pembagian 1.047 untuk melatih model, 225 untuk validasi, dan 225 untuk menguji. Semua citra lebih dulu diseragamkan menjadi 224 × 224 piksel. Setelah model dilatih dan dinilai, model dipasang pada aplikasi web berbasis Streamlit. Pada data uji, *accuracy* mencapai 96% dengan rata-rata *precision* 96,01%, sedangkan *recall* dan *F1-score* masing-masing 96%, sehingga kinerjanya baik pada dataset tersebut. Aplikasi ini diharapkan memberi gambaran awal kondisi buah dari gambar. Meskipun memperoleh hasil pengujian yang baik, model masih memerlukan pengujian lebih lanjut menggunakan citra pisang Ambon yang diambil secara langsung di lingkungan perkebunan dengan kondisi pencahayaan, sudut pengambilan, dan latar belakang yang beragam untuk mengetahui kinerjanya dalam kondisi nyata.

Kata kunci: Kecerdasan Buatan, AI Fruit Scanner, *Transfer learning*, tingkat kematangan pisang, Streamlit.

ABSTRACT

Inspecting banana trees one by one to judge when fruit is ready is slow and labor-intensive on large plantations. To ease this work, this study develops AI Fruit Scanner, an AI-powered application that examines a banana image and assigns it to one of three classes: unripe, ripe, or rotten. The model is built by transfer learning on MobileNetV2. The data consist of 1,497 images, balanced at 499 per class and divided into 1,047 for training, 225 for validation, and 225 for testing; all images were standardized to 224 × 224 pixels beforehand. After the model was trained and assessed, it was deployed through a Streamlit web interface. On the held-out test images it reached 96% accuracy and 96.01% average precision, with recall and F1-score both at 96%, indicating good performance on this dataset. The application is meant to give users a quick first look at fruit condition from images. Although the model achieved good testing results, further evaluation using Ambon banana images captured directly in plantation environments under varying lighting conditions, shooting angles, and backgrounds is still required to assess its performance in real-world conditions.

Keywords: *Artificial Intelligence, AI Fruit Scanner, transfer learning, banana ripeness level, Streamlit.*

1. PENDAHULUAN

Di kebun pisang yang luas, petani harus menilai buah satu per satu untuk memutuskan apakah buah pisang sudah layak dipanen, perlu ditangani, atau sudah rusak. Pekerjaan ini menyita waktu dan tenaga, dan karena bergantung pada mata masing-masing orang, penilaiannya bisa berbeda antarpemeriksa. Karena itu dibutuhkan alat yang dapat menyimpulkan kondisi pisang hanya dari fotonya. Kemampuan komputer menganalisis gambar berkembang pesat seiring kemajuan kecerdasan buatan. Model dapat menilai sebuah foto dari ciri visualnya, dan *Convolutional Neural Network*

(CNN) menjadi salah satu pendekatan yang banyak dipilih karena mampu menemukan pola langsung dari gambar. Pada pisang, MobileNetV2 pernah dipakai untuk membedakan jenisnya [1], dan kombinasi MobileNetV2 dengan *transfer learning* pernah diuji untuk menentukan tingkat kematangannya [2]. Pengenalan tahap kematangan melalui *deep learning* juga telah dibahas dalam studi lain [3].

Dari studi-studi itu terlihat bahwa hasil klasifikasi dipengaruhi oleh jumlah kategori dan karakter data yang dipakai. Penelitian ini membatasi diri pada tiga kategori, yaitu *Unripe*, *Ripe*, dan *Rotten*, agar keluarannya mudah dibaca pengguna. Model juga perlu diuji dengan gambar yang tidak ikut dipakai saat pelatihan, sehingga kemampuannya pada data baru dapat dinilai. Selain kemampuan dalam melakukan klasifikasi citra, pemilihan arsitektur juga perlu mempertimbangkan kebutuhan komputasi saat model diterapkan. MobileNetV2 digunakan dalam penelitian ini karena memiliki rancangan jaringan yang lebih ringan dan efisien dibandingkan beberapa arsitektur CNN lainnya. Karakteristik tersebut menjadi pertimbangan karena model tidak hanya dilatih untuk memperoleh hasil klasifikasi yang baik, tetapi juga akan diterapkan pada aplikasi berbasis web menggunakan Streamlit. Dengan demikian, penggunaan MobileNetV2 diharapkan dapat mendukung proses klasifikasi tanpa membutuhkan sumber daya komputasi yang terlalu besar.

Penelitian ini membangun AI Fruit Scanner, sebuah aplikasi web yang menjalankan MobileNetV2 hasil *transfer learning* untuk menentukan kondisi pisang. Data berjumlah 1.497 citra seimbang antar kelas, yang dibagi ke dalam tiga subset: pelatihan, validasi, dan pengujian. Hasil pelatihan dipasang pada antarmuka Streamlit, tempat pengguna mengunggah foto dan langsung melihat kelas prediksinya. Model dinilai melalui *accuracy*, *precision*, *recall*, dan *F1-score*. Aplikasi diharapkan memberi gambaran awal kondisi buah dari foto, sedangkan kecocokannya untuk pisang Ambon di kebun sesungguhnya masih harus dibuktikan lewat uji lapangan.

2. TINJAUAN PUSTAKA

2.1 Kecerdasan Buatan dan Klasifikasi Citra

Dalam penelitian ini, kecerdasan buatan (*Artificial Intelligence*, AI) dipahami sebagai ranah ilmu komputer yang menyiapkan komputer agar sanggup menyerap informasi dan menemukan keteraturan dalam data. Klasifikasi citra lahir dari kemampuan itu: sebuah gambar dimasukkan ke kategori tertentu menurut ciri visual yang sudah dipelajari model. Di lahan pertanian, cara ini membantu mengenali kondisi buah hanya dari foto [4]. Untuk keperluan penelitian ini, pisang dipilah ke dalam tiga kelompok melalui klasifikasi citra: *Unripe*, *Ripe*, dan *Rotten*. Sistem menerima ciri visual gambar sebagai masukan, lalu mengeluarkan kategori yang diprediksi [5].

2.2 *Deep Learning* dan *Algoritma Pemrosesan Citra Berbasis CNN*

Jaringan saraf dengan banyak lapisan menjadi inti *deep learning*, yang termasuk dalam kecerdasan buatan dan dipakai untuk menggali pola dari data. Di bidang citra, *Convolutional Neural Network* (CNN) termasuk arsitektur yang paling sering dipilih. CNN belajar membaca gambar lewat warna, tekstur, dan bentuknya, [6].

Kajian-kajian klasifikasi gambar sudah banyak yang memakai CNN, termasuk untuk mengenali kondisi maupun jenis pisang [7]. Ada pula studi yang memilih InceptionV3 dalam mengklasifikasikan citra [8]. Deep learning juga dipakai untuk mendeteksi objek pada citra secara real-time [9]. Penelitian ini sendiri memakai MobileNetV2, dengan mempertimbangkan beban pemrosesan citra pada aplikasi

2.4 Evaluasi Kinerja Model

Tahap evaluasi memeriksa seberapa baik model mengklasifikasikan citra pada data pengujian. Empat ukuran dipakai: *accuracy*, *precision*, *recall*, dan *F1-score*. Keempatnya saling melengkapi dalam menunjukkan ketepatan prediksi dan kemampuan model mengenali tiap kategori [12].

Accuracy dihitung sebagai perbandingan prediksi benar dengan jumlah seluruh data uji, sebagaimana rumus berikut.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.1)$$

Untuk *precision*, yang diukur adalah seberapa sering data yang dimasukkan model ke kelas tertentu memang benar berasal dari kelas itu, dengan rumus berikut.

$$Precision = \frac{TP}{TP+FP} \quad (2.2)$$

Recall menunjukkan seberapa banyak data dari kelas tertentu yang berhasil ditemukan model.

$$Recall = \frac{TP}{TP+FN} \quad (2.3)$$

- ✓ TP (*True Positive*) : jumlah data positif yang berhasil diklasifikasikan dengan benar.
- ✓ TN (*True Negative*) : jumlah data negatif yang berhasil diklasifikasikan dengan benar.
- ✓ FP (*False Positive*) : jumlah data negatif yang salah diklasifikasikan sebagai positif.
- ✓ FN (*False Negative*) : jumlah data positif yang salah diklasifikasikan sebagai negatif

F1-score memadukan *precision* dan *recall* menjadi satu nilai sehingga keseimbangan keduanya dapat dilihat sekaligus.

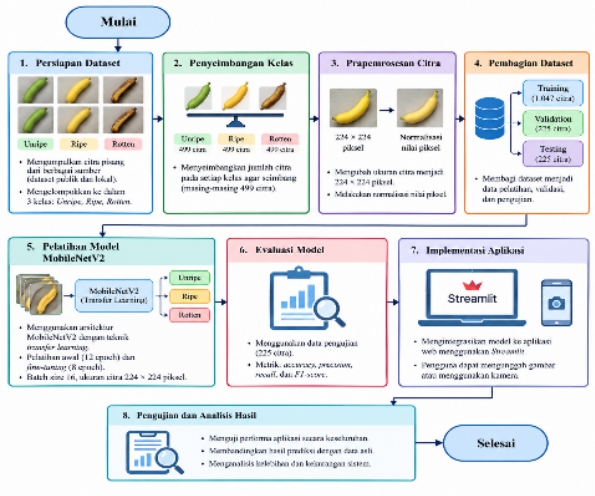
$$F1\text{-}score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (2.4)$$

Dalam rumus-rumus itu, TP (*True Positive*) menghitung data yang kelasnya diprediksi tepat. TN (*True Negative*) menghitung data kelas lain yang memang tidak dimasukkan ke kelas yang dinilai. FP (*False Positive*) muncul ketika data kelas lain keliru dimasukkan ke kelas yang dinilai, sedangkan FN (*False Negative*) muncul ketika data dari kelas yang dinilai justru dimasukkan ke kelas lain. Karena ada tiga kelas, *precision*, *recall*, dan *F1-score* dihitung berdasarkan prediksi tiap kelas.

3. METODE PENELITIAN

Metode yang dipakai adalah eksperimen dengan *deep learning* untuk membuat AI Fruit Scanner. Sistem ini menerima citra digital pisang dan menggolongkannya sebagai *Unripe*, *Ripe*, atau *Rotten*. Modelnya berupa MobileNetV2 yang dilatih dengan *transfer learning*. Alurnya dimulai dari penyiapan dataset dan pengolahan gambar, dilanjutkan pelatihan serta evaluasi model, dan diakhiri dengan pemasangannya pada aplikasi web Streamlit

Penelitian diawali dengan mengelompokkan citra pisang ke dalam tiga kategori kondisi buah, yaitu *Unripe*, *Ripe*, dan *Rotten*. Selanjutnya, jumlah citra pada setiap kategori disesuaikan agar dataset memiliki komposisi kelas yang seimbang. Setelah itu, dataset dibagi menjadi tiga bagian, yaitu *train*, *valid*, dan *test*.



Gambar 1. Tahapan Pengembangan AI Fruit Scanner dari Dataset hingga Aplikasi Web

Berikutnya, gambar disesuaikan ukuran dan nilai pikselnya dengan masukan yang diminta MobileNetV2. Pelatihan memakai data pelatihan, sementara data validasi dipakai untuk memantau jalannya pelatihan. Seusai itu, data pengujian menjadi tolok ukur kemampuan model. Model yang telah siap lalu dipasang pada aplikasi AI Fruit Scanner.

3.2 Persiapan Dataset

Tiga kelas membentuk dataset ini: *Unripe* untuk pisang mentah, *Ripe* untuk pisang matang, dan *Rotten* untuk pisang busuk. Agar seimbang, tiap kelas diberi jatah 499 citra sehingga dataset seluruhnya terdiri atas 1.497 citra. Seluruh citra kemudian dialokasikan ke tiga subset: 1.047 citra untuk pelatihan serta masing-masing 225 citra untuk validasi dan pengujian.

Pembagian per kelas dapat dilihat pada Tabel 1 berikut.

Tabel 1. Rincian Alokasi Citra untuk Melatih, Memvalidasi, dan Menguji Model

Kelas	Pelatihan	Validasi	Pengujian	Total
Unripe	349	75	75	499
Ripe	349	75	75	499
Rotten	349	75	75	499
Total	**1.047**	**225**	**225**	**1.497**

Dengan pembagian itu, tahap pelatihan, pemantauan, dan pengujian masing-masing memakai data yang berbeda, sehingga data pengujian sama sekali tidak terlibat saat model dibentuk.

3.3 Prapemrosesan Citra

Agar sesuai dengan masukan MobileNetV2, semua citra diperkecil atau diperbesar menjadi 224 × 224 piksel, kemudian nilai pikselnya dinormalisasi ke rentang yang diminta model. Dengan begitu, seluruh gambar yang masuk ke tahap pelatihan maupun pengujian memiliki ukuran dan representasi yang sama.

3.4 Pelatihan Model MobileNetV2

Model klasifikasi berpijak pada MobileNetV2 melalui pendekatan *transfer learning*. Bobot hasil pelatihan di ImageNet dipertahankan untuk menarik fitur visual dari gambar, sementara lapisan

klasifikasi di bagian akhir disesuaikan agar keluarannya tiga kategori kondisi pisang. Proses pelatihan dibagi menjadi dua tahap. Lapisan klasifikasi dilatih lebih dulu, lalu sebagian lapisan model dilatih lagi lewat *fine-tuning*. Parameter yang dipakai: gambar 224 × 224 piksel, *batch size* 16, 12 *epoch* pada tahap awal, dan 8 *epoch* untuk *fine-tuning*.

3.5 Evaluasi Model

Sebanyak 225 citra, yang sejak awal dipisahkan dari data pelatihan dan validasi, dipakai untuk menguji model. Tujuannya melihat seberapa tepat model menempatkan gambar ke kategori *Unripe*, *Ripe*, atau *Rotten*. Penilaian memakai empat metrik: *accuracy*, *precision*, *recall*, dan *F1-score*. Dari metrik tersebut dapat dilihat ketepatan prediksi secara umum serta kinerja model pada tiap kelas.

3.6 Implementasi Aplikasi

Model MobileNetV2 hasil pelatihan dibungkus dalam aplikasi web AI Fruit Scanner yang dibuat dengan Streamlit. Gambar dapat dimasukkan lewat unggah berkas atau melalui kamera bila perangkat menyediakannya. Gambar yang masuk lebih dulu diolah agar ukuran dan pengaturannya sesuai dengan model. Selanjutnya model menentukan satu dari tiga kategori kondisi pisang, dan hasilnya muncul di antarmuka sebagai informasi awal untuk pengguna.

4. HASIL DAN PEMBAHASAN

4.1 Proses dan Konfigurasi Pelatihan MobileNetV2

pada setiap kategori, yang kemudian dipecah untuk melatih, memvalidasi, dan menguji model. Semua citra lebih dulu dijadikan 224 × 224 piksel supaya sesuai dengan masukan model.

Ada dua tahap pelatihan. Pada tahap pertama, MobileNetV2 berbobot awal ImageNet dipakai untuk melatih lapisan klasifikasi. Tahap kedua berupa *fine-tuning* pada sebagian lapisan model, agar model lebih memahami ciri citra pisang dalam dataset penelitian.

Pelatihan memakai *batch size* 16, 12 *epoch* pada tahap awal, dan maksimal 8 *epoch* untuk *fine-tuning*. Setelah itu, model diuji pada data pengujian. Pada pengujian, model mencapai akurasi 96%, artinya sebagian besar citra uji terklasifikasi sesuai kategori aslinya. Meski begitu, performanya pada citra di luar dataset penelitian belum diketahui dan masih perlu diuji.

4.2 Hasil Evaluasi Model

Pengujian menggunakan 225 citra, yaitu 75 untuk masing-masing kelas, guna melihat seberapa baik MobileNetV2 menentukan kondisi pisang menurut kategori yang ditetapkan. Metrik yang dipakai adalah *accuracy*, *precision*, *recall*, dan *F1-score*; nilainya terangkum pada Tabel 2.

Tabel 2. Nilai Accuracy, Precision, Recall, dan F1-score pada 225 Citra Uji

Metrik Evaluasi	Nilai
Accuracy	96,00%
Precision rata-rata	96,01%
Recall rata-rata	96,00%
F1-score rata-rata	96,00%

Tabel 2 menunjukkan akurasi 96,00%, yang berarti 216 dari 225 citra uji diklasifikasikan benar dan 9 citra lainnya keliru. Rata-rata *precision* 96,01% menunjukkan bahwa prediksi model sebagian besar

tepat. *Recall* sebesar 96,00% memperlihatkan bahwa model berhasil mengenali citra sesuai kelas aslinya, dan *F1-score* 96,00% menandakan kedua ukuran itu berimbang di setiap kategori. Walau hasilnya baik, pengujian ini baru mencakup dataset penelitian. Kinerja model di luar itu belum diketahui, sehingga perlu diuji dengan citra yang diambil pada pencahayaan, sudut, dan latar belakang berbeda.

4.3 Analisis *Matriks Evaluasi Klasifikasi*

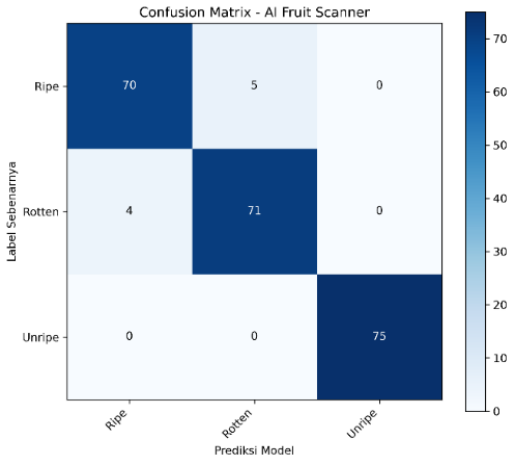
Untuk melihat kinerja pada tiap kategori, hasil prediksi dirangkum dalam *confusion matrix* (Tabel 3), yang menyandingkan label sebenarnya dengan prediksi MobileNetV2.

Tabel 3. Confusion Matrix Model MobileNetV2

Kelas	Prediksi Ripe	Prediksi Rotten	Prediksi Unripe
Ripe	70	5	0
Rotten	4	71	0
Unripe	0	0	75

Tabel 3 memperlihatkan bahwa dari 75 citra *Ripe*, 70 diprediksi benar dan 5 dikira *Rotten*. Pada kelas *Rotten*, 71 citra dikenali dengan benar dan 4 dikira *Ripe*. Kelas *Unripe* berbeda: ke-75 citranya diprediksi benar. Dengan kata lain, model tidak mengalami kesulitan mengenali pisang mentah pada data uji ini. Jika dihitung dari Tabel 3, *recall* per kelas adalah 100% untuk *Unripe*, 93,33% untuk *Ripe*, dan 94,67% untuk *Rotten*, dengan *precision* masing-masing (100%, 94,59%, dan 93,42%). Rata-rata *precision* dihitung dari nilai per kelas sebelum dibulatkan (100%; 94,5946%; dan 93,4211%), sehingga hasilnya 96,01%.

Semua kekeliruan terjadi pada pasangan *Ripe* dan *Rotten*, yang mengisyaratkan bahwa sebagian citra kedua kelas tampak serupa bagi model. Untuk mencari penyebabnya, warna, tekstur, dan kondisi permukaan buah pada citra yang salah bisa diperiksa lebih dalam.



Gambar 2. Visualisasi Confusion Matrix Model MobileNetV2

Karena kekeliruan hanya terjadi antara *Ripe* dan *Rotten*, kemiripan visual pada sebagian citra menjadi dugaan penyebabnya. Dugaan itu baru bisa dipastikan setelah citra-citra yang salah diklasifikasikan diperiksa satu per satu.



(a) *(b)*

Gambar 3. Contoh Kesalahan Klasifikasi pada Kelas Ripe dan Rotten
Gambar (a) Citra Ripe yang diprediksi sebagai Rotten dengan confidence 93,67%.
Gambar (b) Citra Rotten yang diprediksi sebagai Ripe dengan confidence 92,47%.

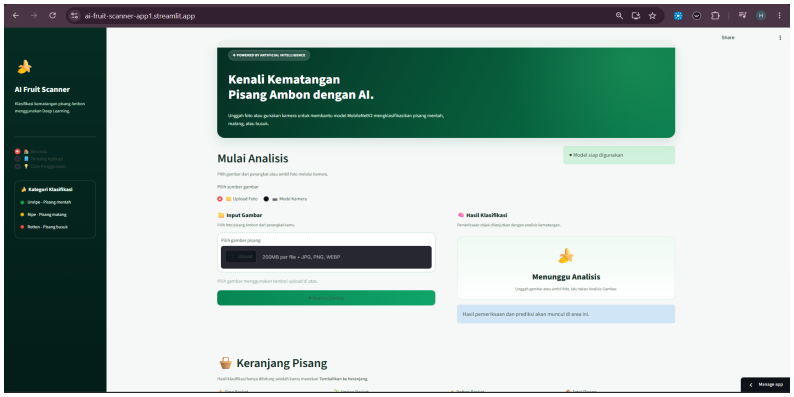
Gambar 3 memperlihatkan dua contoh citra yang mengalami kesalahan klasifikasi. Pada contoh pertama, citra dengan kelas sebenarnya *Ripe* diprediksi sebagai *Rotten* dengan nilai *confidence* sebesar 93,67%. Hal ini diduga karena kulit pisang memiliki bercak berwarna cokelat tua hingga kehitaman yang menyerupai karakteristik pisang busuk.

Pada contoh kedua, citra dengan kelas sebenarnya *Rotten* diprediksi sebagai *Ripe* dengan nilai *confidence* sebesar 92,47%. Kesalahan ini kemungkinan dipengaruhi oleh masih terlihatnya bagian kulit berwarna kuning pada buah, meskipun terdapat bercak gelap di beberapa bagian permukaannya. Kedua contoh tersebut menunjukkan bahwa kemiripan warna dan tekstur kulit pisang dapat menjadi salah satu faktor yang menyebabkan model kesulitan membedakan kelas *Ripe* dan *Rotten*. Selain itu, nilai *confidence* yang tinggi tidak selalu menjamin bahwa hasil prediksi model benar.

4.4 Implementasi Aplikasi AI Fruit Scanner

Model MobileNetV2 hasil pelatihan ditanamkan dalam AI Fruit Scanner, aplikasi web berbasis Streamlit yang memudahkan pengguna mengetahui kondisi pisang dari gambar. Pengguna dapat memberi gambar lewat unggah berkas, atau memakai kamera jika perangkatnya mendukung. Gambar itu lalu diubah menjadi 224 × 224 piksel dan dinormalisasi sesuai kebutuhan model. Sesudah prapemrosesan, MobileNetV2 menetapkan kondisi pisang sebagai *Unripe*, *Ripe*, atau *Rotten*. Antarmuka menampilkan kategori buah beserta tingkat keyakinan model, sepanjang fitur tersedia.

Karena model sudah dilatih sebelumnya, pengguna tidak perlu menjalankan pelatihan untuk mendapatkan hasil. AI Fruit Scanner pun bisa dipakai sebagai pembantu untuk memperoleh gambaran awal kondisi pisang dari citra digital. Meski demikian, kualitas gambar dan kemampuan model mengenali ciri visual yang ada dalam dataset penelitian tetap memengaruhi hasil klasifikasi. Adapun tampilan aplikasi AI Fruit Scanner seperti pada gambar 4 berikut:



Gambar 4. Tampilan Aplikasi AI Fruit Scanner

4.5 Pembahasan Temuan dan Keterbatasan Penelitian

Pada dataset pengujian, kombinasi *transfer learning* dan MobileNetV2 menghasilkan akurasi 96,00%. Model terbukti dapat memisahkan tiga kondisi pisang, *Unripe*, *Ripe*, dan *Rotten*, dengan baik pada data yang dipakai.

Fitur visual yang sudah dipelajari MobileNetV2 dari ImageNet menjadi modal klasifikasi, lalu disesuaikan dengan pelatihan pada dataset penelitian sehingga model mampu mengenali ciri citra pisang pada tiap kategori.

Confusion matrix mengungkap kekeliruan pada kelas *Ripe* dan *Rotten*: lima citra *Ripe* dikira *Rotten*, dan empat citra *Rotten* dikira *Ripe*. Ini menandakan model masih sulit memisahkan sebagian citra kedua kelas. Warna, tekstur, dan kondisi permukaan buah yang mirip layak diperiksa sebagai kemungkinan penyebab. Untuk kelas *Unripe*, semua citra uji terprediksi benar. Namun, ini hanya menggambarkan kinerja pada dataset yang dipakai, bukan jaminan hasil serupa pada setiap kondisi pengambilan gambar.

Dalam penggunaan, AI Fruit Scanner dapat memberi pengguna gambaran awal kondisi pisang dari citra digital dan berpotensi mempercepat pemeriksaan bila gambarnya banyak. Meski begitu, prediksinya sebaiknya diperlakukan sebagai informasi pendukung dan tidak menggantikan pemeriksaan langsung pada buah.

Penelitian ini merupakan tahap awal pengembangan sistem klasifikasi kematangan pisang yang nantinya diarahkan untuk membantu mengenali kondisi pisang Ambon. Namun, dataset yang digunakan dalam pelatihan dan pengujian belum dapat dijadikan bukti bahwa model telah mampu mengklasifikasikan varietas pisang Ambon secara khusus. Oleh karena itu, diperlukan pengujian lanjutan menggunakan citra pisang Ambon yang telah terverifikasi dan diambil secara langsung di lingkungan perkebunan dengan kondisi pencahayaan, sudut pengambilan, serta latar belakang yang beragam.

5. KESIMPULAN

Penelitian melahirkan AI Fruit Scanner, aplikasi web yang mengklasifikasikan kondisi pisang menjadi *Unripe*, *Ripe*, dan *Rotten* dengan MobileNetV2 dan *transfer learning*. Modelnya dilatih dari 1.497 citra yang telah diseimbangkan dan dipecah untuk pelatihan, validasi, serta pengujian. Dari 225 citra uji, akurasi yang dicapai adalah 96,00%, dengan rata-rata *precision* 96,01% serta *recall* dan *F1-score* masing-masing 96,00%. MobileNetV2 dengan demikian bekerja baik pada dataset ini, meski masih keliru membedakan sebagian citra *Ripe* dan *Rotten*.

Sebagai alat bantu, AI Fruit Scanner memberi gambaran awal kondisi pisang dari citra digital. Ke depan, aplikasi dapat dilengkapi fitur penghitung jumlah pisang per kategori dan dilatih dengan dataset yang lebih beragam. Uji langsung pada pisang Ambon di perkebunan juga diperlukan untuk mengetahui kinerja model di kondisi nyata. Meskipun memperoleh hasil pengujian yang baik, model dalam penelitian ini belum secara khusus divalidasi menggunakan citra pisang Ambon yang telah terverifikasi. Oleh karena itu, diperlukan pengujian lebih lanjut menggunakan citra pisang Ambon yang diambil secara langsung di lingkungan perkebunan dengan kondisi pencahayaan, sudut pengambilan, dan latar belakang yang beragam untuk mengetahui kemampuan model dalam kondisi nyata.

DAFTAR PUSTAKA

[1] C. Nastitie and I. Handayani, "Perbandingan metode MobileNetV2 dan EfficientNetB0 untuk klasifikasi jenis pisang," *INTECOMS: Journal of Information Technology and Computer Science*, vol. 8, no. 6, pp. 1990–1999, 2025, doi: 10.31539/0240cx09.

[2] A. Mufidh and S. R. Nudin, "Implementasi model MobileNetV2 dalam pengembangan sistem prediksi kematangan pisang berbasis mobile," *TIN: Terapan Informatika Nusantara*, vol. 6, no. 11, pp. 2044–2054, 2026, doi: 10.47065/tin.v6i11.9559.

[3] A. D. Arsianto and Hustinawaty, "Klasifikasi tingkat kematangan pisang menggunakan metode deep learning dengan CNN," *Jurnal Ilmiah Sistem Informasi dan Ilmu Komputer*, vol. 6, no. 1, pp. 342–355, 2026, doi: 10.55606/juisik.v6i1.2143.

[4] L. Yang, B. Cui, J. Wu, X. Xiao, Y. Luo, Q. Peng, and Y. Zhang, "Automatic detection of banana maturity—application of image recognition in agricultural production," *Processes*, vol. 12, no. 4, Art. no. 799, 2024, doi: 10.3390/pr12040799.

[5] M. R. Z. Ramadhan and A. L. Pramana, "Pengenalan tingkat kematangan buah pisang berbasis citra dengan metode convolutional neural network," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 10, no. 3, pp. 4191–4199, 2026, doi: 10.36040/jati.v10i3.18150.

[6] D. W. Rahayu, D. Setiadi, and D. Yuniarto, "Penerapan deep learning untuk klasifikasi buah berdasarkan citra dengan metode convolutional neural networks," *Indonesian Journal of Education and Computer Science*, vol. 2, no. 3, pp. 196–202, 2024, doi: 10.60076/indotech.v2i3.978

[7] T. N. A. Febriana and V. Lusiana, "Klasifikasi tingkat kematangan buah pisang raja menggunakan metode CNN berbasis Android," *Jurnal Teknologi Sistem Informasi dan Aplikasi*, vol. 7, no. 1, pp. 176–184, 2024, doi: 10.32493/jtsi.v7i1.37790.

[8] N. W. Wulansari and Muslih, "Implementasi metode convolutional neural network untuk deteksi kematangan buah pisang menggunakan Inception V3," *Journal of Information System*, vol. 8, no. 2, pp. 147–155, 2023, doi: 10.33633/joins.v8i2.9074.

[9] M. J. Wahyuda, "Sistem machine learning You Only Look Once untuk identifikasi pelaku pembuang sampah secara real-time," *Jurnal TELISKA*, vol. 18, no. 2, pp. 15–27, 2025, doi: 10.5281/zenodo.15855681.

[10] Y. Gulzar, "Fruit image classification model based on MobileNetV2 with deep transfer learning technique," *Sustainability*, vol. 15, no. 3, Art. no. 1906, 2023, doi: 10.3390/su15031906.

[11] J. Plested, M. Phiri, and T. Gedeon, "Deep transfer learning for image classification: A survey," *Artificial Intelligence Review*, vol. 59, Art. no. 100, 2026, doi: 10.1007/s10462-026-11491-z.

[12] O. Rainio, J. Teuho, and R. Klén, "*Evaluation metrics and statistical tests for machine learning*," *Scientific Reports*, vol. 14, no. 1, Art. no. 6086, 2024, doi: 10.1038/s41598-024-56706-x.