



Implementasi Model MobileNetV2 dalam Pengembangan Sistem Prediksi Kematangan Pisang Berbasis Mobile

Ainul Mufidh^{*}, Salamun Rohman Nudin

Fakultas Vokasi, Program Studi Manajemen Informatika, Universitas Negeri Surabaya, Surabaya, Indonesia

Email: ^{1,*}ainulmufidh.22028@mhs.unesa.ac.id, ²salamunrohman@unesa.ac.id,

Email Penulis Korespondensi: ainulmufidh.22028@mhs.unesa.ac.id

Abstrak—Pisang merupakan komoditas buah tropis bernilai nutrisi tinggi yang banyak dikonsumsi masyarakat. Namun, proses identifikasi tingkat kematangan yang masih dilakukan secara manual sering menimbulkan ketidakkonsistenan. Kebun Pisang Pak Sanali di Kecamatan Krembung, Kabupaten Sidoarjo, menghadapi kendala dalam menentukan kematangan buah secara akurat, sehingga berpotensi menyebabkan kesalahan sortasi yang berdampak pada kualitas dan nilai jual hasil panen. Penelitian ini bertujuan merancang sistem prediksi tingkat kematangan pisang berbasis citra menggunakan pendekatan *Deep Learning*. Model yang digunakan adalah *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNetV2* yang menerapkan *transfer learning*. Proses dimulai dari input citra pisang yang melalui tahap preprocessing berupa augmentasi dan normalisasi, kemudian diekstraksi fiturnya melalui lapisan convolutional untuk menangkap karakteristik visual seperti warna dan tekstur kulit pisang. Fitur tersebut selanjutnya diproses pada lapisan *classification head* yang terdiri dari *Global Average Pooling* dan *fully connected layer* untuk menghasilkan prediksi empat kelas kematangan, yaitu *unripe*, *ripe*, *overripe*, dan *rotten*. Hasil pengujian menunjukkan bahwa model dengan optimizer *Adam* memberikan performa terbaik dengan akurasi sebesar 99,47% dan test loss sebesar 0,39%. Model dikembangkan menggunakan Python dan *TensorFlow* pada Google Colaboratory, serta diimplementasikan dalam aplikasi berbasis Kotlin. Evaluasi menggunakan confusion matrix menunjukkan kinerja klasifikasi yang sangat baik berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

Kata Kunci: Prediksi Kematangan Pisang; *MobileNetV2*; *Deep Learning*; *Transfer Learning*; *Computer Vision*

Abstract—Bananas are a highly nutritious tropical fruit widely consumed by the public. However, the manual process of determining ripeness levels often leads to inconsistencies. Pak Sanali's Banana Plantation in Krembung Subdistrict, Sidoarjo Regency, faces challenges in accurately determining fruit ripeness, which can potentially cause sorting errors that impact the quality and market value of the harvest. This study aims to design an image-based banana ripeness prediction system using a Deep Learning approach. The model used is a Convolutional Neural Network (CNN) with a MobileNetV2 architecture that employs transfer learning. The process begins with banana image inputs that undergo preprocessing stages of augmentation and normalization, followed by feature extraction through convolutional layers to capture visual characteristics such as the color and texture of the banana peel. These features are then processed in the classification head layer, consisting of Global Average Pooling and a fully connected layer, to generate predictions for four ripeness classes: unripe, ripe, overripe, and rotten. Test results show that the model using the Adam optimizer delivers the best performance, with an accuracy of 99.47% and a test loss of 0.39%. The model was developed using Python and TensorFlow on Google Colaboratory and implemented in a Kotlin-based application. Evaluation using a confusion matrix demonstrates excellent classification performance based on the metrics of accuracy, precision, recall, and F1-score.

Keywords: Banana Ripeness Prediction; *MobileNetV2*; *Deep Learning*; *Transfer Learning*; *Computer Vision*

1. PENDAHULUAN

Pisang termasuk salah satu komoditas buah tropis yang memiliki kandungan gizi tinggi seperti vitamin, karbohidrat, serat, serta berbagai mineral yang bermanfaat bagi kesehatan manusia. Selain menjadi sumber energi yang cepat, pisang juga berperan besar dalam perekonomian Indonesia karena tingginya tingkat konsumsi masyarakat (Kosasih, 2021). Kebun Pisang Pak Sanali di Kecamatan Krembung, Kabupaten Sidoarjo, menghadapi kendala dalam menentukan kematangan buah secara akurat, sehingga berpotensi menyebabkan kesalahan sortasi yang berdampak pada kualitas dan nilai jual hasil panen. Sesuai data Badan Pusat Statistik (BPS), produksi pisang nasional pada tahun 2024 mencapai 9,26 juta ton, menjadikannya komoditas buah dengan produksi terbesar di Indonesia (BPS, 2025). Menyadari volume produksi yang sangat besar, penting bagi para petani dan pengusaha hortikultura untuk memastikan nilai jual tetap tinggi dan tidak terjadi kerugian pasca panen (Wicaksono, 2023). Permasalahan yang sering ditemui adalah dalam menentukan tingkat kematangan buah pisang yang dilakukan secara manual. Proses penilaian selama ini mengandalkan pengamatan visual yang sering memunculkan ketidakseragaman dalam menentukan apakah pisang berada pada kondisi matang siap konsumsi, terlalu matang, atau sudah memasuki tahap pembusukan (Hanifah & Hermawan, 2023). Ketidaktepatan ini berdampak langsung pada kualitas hasil panen yang akan dijual serta menimbulkan potensi kerugian akibat salah dalam penilaian, seperti pisang yang terlihat terlalu matang namun ternyata sudah melewati batas konsumsi. Selain itu, perbedaan fisik antara pisang terlalu matang dan busuk terkadang sulit dibedakan secara langsung sehingga membuat proses pemilahan menjadi tidak efisien dan rawan kesalahan (Simanjuntak & Muhathir, 2025). Keterbatasan tersebut menyulitkan petani maupun pelaku usaha untuk menjaga konsistensi mutu, memperpanjang umur simpan, serta meminimalkan produk terbuang yang pada akhirnya berpengaruh terhadap pendapatan dan keberlanjutan usaha (Pangestu et al., 2024). Untuk mengatasi masalah dalam menentukan kematangan pisang, salah satu solusi teknologi yang dapat digunakan ialah pengolahan citra digital (*image processing*). Pemanfaatan *image processing* memungkinkan memprediksi kematangan pisang yang dapat dilakukan secara otomatis dan presisi secara visual sehingga pengelola pertanian dapat menentukan kematangan pisang yang lebih efektif, cepat dan hasil yang konsisten (Archana & Jeevaraj, 2024).



Dalam bidang pengolahan citra, pendekatan Deep Learning khususnya Convolutional Neural Network (CNN) telah banyak digunakan dalam berbagai tugas pengenalan pola visual seperti klasifikasi citra, deteksi objek, serta segmentasi gambar (Hadhiwibowo et al., 2024). Keunggulan utama CNN terletak pada kemampuannya dalam mengekstraksi fitur visual secara otomatis melalui jaringan saraf berlapis yang mampu mempelajari pola kompleks dari data citra (Adão et al., 2022). Untuk meningkatkan efisiensi *Convolutional Neural Network (CNN)*, penggunaan transfer learning diterapkan dengan memanfaatkan model yang sudah dilatih sebelumnya (*pre-trained model*). Pendekatan ini mampu meningkatkan performa jaringan saraf karena model telah dipelajari menggunakan dataset berukuran besar. Dengan demikian, proses pelatihan menjadi lebih cepat serta tetap memberikan hasil yang optimal meskipun menggunakan jumlah dataset yang relatif lebih sedikit (Rafi et al., 2025). Salah satu implementasi dalam *transfer learning* adalah *feature extraction* yang merupakan proses ekstraksi fitur citra dengan menggunakan *pre-trained model* untuk menghasilkan representasi fitur. Dalam penelitian arsitektur yang digunakan adalah *MobileNetV2*, yaitu model yang dikembangkan oleh Google dengan menerapkan konsep *inverted residuals* dan *linear bottleneck*. Arsitektur tersebut dirancang untuk memberikan keseimbangan antara tingkat akurasi dan efisiensi komputasi, sehingga sangat cocok untuk digunakan untuk pengolahan gambar pada perangkat yang memiliki keterbatasan komputasi (Yong et al., 2023).

Penelitian sebelumnya mengembangkan model untuk mengklasifikasikan tingkat kematangan pisang menggunakan metode *Vision Transformer (ViT)* ke dalam empat kategori, yaitu mentah, setengah matang, matang, dan terlalu matang. Penelitian tersebut memanfaatkan lima arsitektur ViT yang telah dilatih sebelumnya (*pre-trained*), yaitu ViT-B/16, ViT-B/32, ViT-L/16, ViT-L/32, dan ViT-H/14 yang dilatih menggunakan dataset *ImageNet-21k* dan *ImageNet-1k*. Selanjutnya, performa model *Vision Transformer* tersebut dinilai serta dibandingkan dengan model *Convolutional Neural Network (CNN)*. Evaluasi dilakukan dengan metode *cross-dataset* terhadap 5.068 gambar pisang yang diambil dari kumpulan data yang berbeda dari yang digunakan dalam pelatihan. Hasil dari tes menunjukkan bahwa model ViT-L/16-in21k mencatatkan akurasi maksimal sebesar 91,61%. Penemuan ini mengindikasikan bahwa model *Vision Transformer (ViT)* memiliki kemampuan generalisasi yang lebih unggul, sementara model *Convolutional Neural Network (CNN)* memberikan keuntungan dalam hal ukuran model yang lebih kecil dan waktu pelatihan yang lebih efisien (Chuquimarca et al., 2025).

Dalam penelitian lain yang dilakukan menunjukkan peningkatan performa yang lebih baik (Chaowalittawi et al., 2025) mengembangkan model menggunakan *lightweight CNN* untuk klasifikasi kematangan pisang ke dalam empat kelas yaitu *overripe*, *ripe*, *rotten* dan *unripe* dengan menggunakan 13.478 data gambar dan di bagi menjadi 56% untuk data training, 14% untuk validation dan 30% untuk testing. Teknik normalisasi dan augmentasi gambar diterapkan untuk meningkatkan ketahanan model. Penelitian ini menunjukkan bahwa arsitektur *MobileNetV2* dapat memberikan hasil terbaik dengan akurasi train 96,69% dan akurasi validation 96,71%. Sistem ini bertujuan untuk mengprediksikan kematangan pisang yang di integrasikan ke aplikasi Line untuk menyediakan antarmuka yang intuitif.

Meskipun beberapa penelitian sebelumnya telah menunjukkan hasil yang cukup baik, masih terdapat celah penelitian yang perlu dikembangkan. Mayoritas studi terdahulu seperti penelitian yang dilakukan oleh (Chuquimarca et al., 2025), (Kosasih, 2021) dan (Chaowalittawi et al., 2025), hanya terbatas dalam pengembangan model, sehingga belum ada sistem yang bisa digunakan dengan perangkat dengan sumber daya yang terbatas. Oleh karena itu, studi ini bertujuan untuk mengatasi kekurangan ini dengan memanfaatkan arsitektur *MobileNetV2* dan menggunakan 13.478 gambar yang diperoleh dari kaggle. Kebaharuan utama dalam penelitian ini terletak pada penerapan model ke dalam sistem berbasis mobile dalam memprediksi kematangan pisang yang dapat menjadi alat yang dapat membantu dalam pengembangan teknologi di bidang pertanian.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

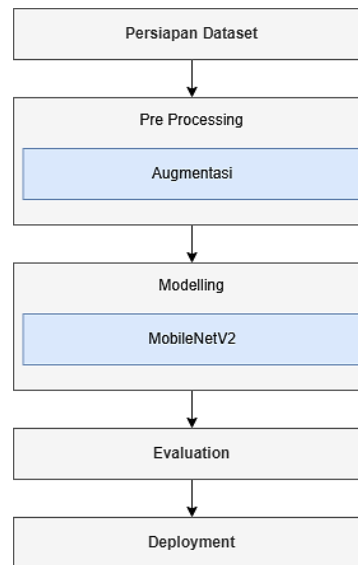
Penelitian ini berfokus pada penerapan teknologi kecerdasan buatan untuk meningkatkan akurasi dan efisiensi dalam proses prediksi tingkat kematangan pisang. Permasalahan yang ditemui dalam penentuan kematangan pisang adalah metode penilaian yang masih dilakukan secara manual, seperti perubahan warna kulit buah. Pendekatan manual tersebut cenderung bersifat subjektif, memerlukan waktu yang relatif lama, serta rentan terhadap kesalahan manusia (Hanifah & Hermawan, 2023). Kondisi ini menjadi kendala ketika proses identifikasi harus dilakukan secara cepat dan konsisten, terutama pada skala produksi atau distribusi yang lebih besar. Oleh karena itu, penelitian ini memanfaatkan pendekatan *Deep Learning* yaitu *Convolutional Neural Networks (CNN)* dengan arsitektur *MobileNetV2* untuk mengekstraksi fitur citra secara otomatis dan menghasilkan sistem prediksi kematangan pisang yang dapat diimplementasikan pada perangkat mobile. *MobileNetV2* dirancang khusus untuk perangkat yang memiliki keterbatasan sumber daya dengan penerapan *inverted residuals* dan *linear bottlenecks*. Efisiensi komputasi pada *MobileNetV2* semakin ditingkatkan melalui penerapan teknik *Depthwise Separable Convolution*. Metode ini memecah proses konvolusi standar menjadi dua tahapan operasi yang terpisah, yaitu *depthwise convolution* yang berfungsi melakukan proses pemfilteran secara lebih ringan pada setiap kanal, serta *pointwise convolution* atau konvolusi berukuran 1×1 yang digunakan untuk menggabungkan dan membentuk kombinasi fitur secara linear (Yong et al., 2023). Pendekatan ini mampu mengurangi biaya komputasi dibandingkan dengan konvolusi standar dengan hanya sedikit penurunan akurasi, menjadikannya ideal untuk aplikasi prediksi kematangan pisang. Metode *Transfer Learning* diterapkan dalam penelitian ini agar dapat

menggunakan model seperti *ImageNet* yaitu model yang dilatih sebelumnya pada dataset berskala besar, yang bertujuan menyelesaikan tugas baru dengan dataset yang lebih spesifik. Penggunaan *Transfer Learning* terbukti dapat mengurangi waktu pelatihan dan penggunaan komputasi (Yu et al., 2022).

Untuk mendukung dalam implementasi ke dalam aplikasi mobile, setelah melakukan *training* model kemudian akan ditransformasi ke versi *TensorFlow Lite* (tflite). TFLite disusun untuk menjalankan proses *Machine Learning* pada perangkat *embedded* serta seluler dengan latensi rendah tanpa memerlukan koneksi yang konstan (Baglat et al., 2023), sehingga pengguna dapat selalu menggunakan aplikasi tanpa bergantung pada koneksi internet. Pada tahap konversi model, dapat diterapkan teknik optimasi seperti kuantisasi (*quantization*). Metode ini bekerja dengan menurunkan tingkat presisi representasi bobot model, misalnya dari float32 menjadi int8, sehingga ukuran model menjadi lebih kecil dan proses komputasi pada CPU maupun akselerator perangkat keras dapat berlangsung lebih cepat tanpa menimbulkan penurunan akurasi yang signifikan. Penerapan teknologi tersebut memungkinkan pengembangan sistem prediksi kematangan pisang yang lebih efisien, objektif, serta mudah diakses melalui perangkat mobile, sehingga proses identifikasi tingkat kematangan pisang dapat dilakukan dengan lebih cepat dan konsisten.

2.2 Tahap Pengembangan

Pengembangan sistem ini dilakukan melalui lima tahap. Pertama yaitu pengumpulan dataset didapatkan dari *Kaggle*. Selanjutnya tahap *pre-processing* dan augmentasi data akan dilakukan dengan normalisasi resolusi 224x224 piksel dengan 3 channel (RGB). Setelah itu melakukan pengembangan model menggunakan *transfer learning* dengan arsitektur *MobileNetV2* yang terdapat dua fase pelatihan yaitu fase *frozen* dan fase *fine tuning* untuk adaptasi fitur yang lebih spesifik. Untuk mencegah model overfitting perlu penerapan *early stopping* (Chamseddine et al., 2022). Selanjutnya model akan dievaluasi dengan menggunakan *confusion matrix* yang berisi *Precision*, *Recall* dan *F1-Score* pada data test yang belum dilihat oleh model, analisis metrik tersebut digunakan untuk mendeteksi kesalahan klasifikasi dan overfitting. Terakhir, setelah melakukan evaluasi model akan di konversi pada format *TensorFlow Lite* yang akan diintegrasikan ke aplikasi mobile dengan menggunakan bahasa pemrograman Kotlin untuk *deployment* dengan inferensi secara *real-time* (Zhu & Huang, 2022).




Gambar 1. Alur Pengembangan Sistem

2.3 Persiapan Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset publik yang diperoleh dari platform *Kaggle* dengan jumlah 13.478 data gambar. Dataset mencakup tingkat kematangan pisang yang terbagi dalam empat kategori yaitu *overripe*, *ripe*, *rotten* dan *unripe*. Dataset terbagi menjadi data training 11,793 gambar (87%), data validation 1,123 gambar (8%), dan data test 562 gambar (4%). Resolusi yang digunakan untuk mengambil seluruh gambar pada dataset ini adalah 416x416. Rincian distribusi jumlah data untuk setiap kelas kematangan pisang ditampilkan pada Tabel 1.

Tabel 1. Label dan Jumlah Dataset

Label	Training	Validation	Test
Unripe	1.902	167	110
Ripe	3.522	339	154
Overripe	2.349	229	113
Rotten	4.020	388	185
Total			13.478



Gambar 2. Banana Ripeness Dataset

Gambar 2 menunjukkan Bananan Ripenes dataset yang terbagi menjadi empat kelas yaitu unripe, ripe, overripe dan rotten. Pada baris pertama merupakan gambar dari kelas unripe atau mentah, baris kedua merupakan gambar dari kelas ripe atau matang, baris ketiga merupakan gambar dari kelas overripe atau terlalu matang dan baris empat merupakan gambar dari kelas rotten atau busuk.

2.4 Pre-Processing Data

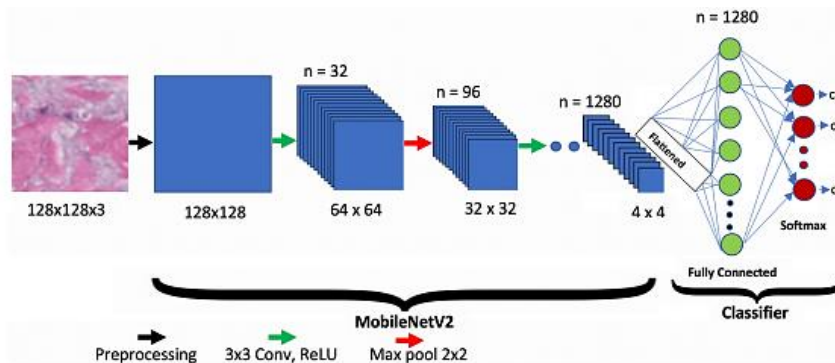
Penelitian ini menerapkan teknik augmentasi rotasi acak, *width* dan *height shift*, transformasi *shear*, transformasi *zoom*, *horizontal flip*, *brightness* dan *fill mode* yang digunakan untuk menambah keragaman data training yang membuat model lebih tangguh dalam menangani variasi gambar dalam berbagai kondisi. Model dilatih untuk memprediksi empat tingkat kematangan pisang yaitu *unripe*, *ripe*, *overripe* dan *rotten*. Proses ini dimulai dengan melakukan normalisasi citra dari ukuran asli dataset yaitu 416x416 di ubah ke ukuran 224x224 piksel untuk menyesuaikan spesifikasi input dari model *MobileNetV2*. Dataset yang didapatkan dari Kaggle sudah di segmentasi dengan pembagian data training 87%, data validation 8% dan data test 4%, sehingga tidak perlu lagi melakukan segmentasi dataset.

Tabel 2. Parameter Augmentasi Data

Parameter	Nilai
Rotasi Acak	Hingga 15°
Width & Height Shift	0.1
Transformasi Shear	0.2
Transformasi Zoom	0.15
Pembalikan Horizontal	True
Modulasi Kecerahan	[0.85, 1.15]
Model Fill	Nearest

2.5 Modelling

Model kecerdasan buatan yang dikembangkan dalam penelitian ini mengadopsi strategi *Deep Learning* yang didasarkan pada *Convolutional Neural Network (CNN)*, serta penggunaan teknik *transfer learning* (Irawati et al., 2024). Arsitektur *MobileNetV2* dipilih karena dapat memberikan keseimbangan yang baik antara tingkat akurasi klasifikasi dan efisiensi komputasi, sehingga cocok diterapkan pada perangkat mobile yang memiliki keterbatasan komputasi. Model ini memiliki sekitar 154 lapisan konvolusi yang dioptimalkan melalui mekanisme *inverted residual blocks* serta *depthwise separable convolution*, sehingga mampu menurunkan kebutuhan komputasi secara signifikan, bahkan hingga beberapa kali lebih efisien dibandingkan konvolusi standar, tanpa mengurangi performa akurasi secara signifikan (Yu et al., 2022).



Gambar 3. Arsitektur *MobileNetV2* (Akay et al., 2021)

Gambar 3 menunjukkan arsitektur *MobileNetV2* yang diimplementasikan dalam penelitian ini. Arsitektur ini terdiri dari base *MobileNetV2 pre-trained* sebagai *feature extractor* dan custom *classification head* untuk klasifikasi empat kelas tingkat kematangan pisang. Base model *MobileNetV2* menggunakan 154 lapisan yang telah dilatih pada dataset *ImageNet*, dioptimalkan dengan *inverted residuals blocks* dan *depthwise separable convolution* untuk memaksimalkan efisiensi komputasi. Kemudian *Custom Head* dirancang khusus untuk adaptasi output *base model* pada



tugas klasifikasi yang menggabungkan *global average pooling layers*, *ReLU*, *batch normalization* dan *dropout layers* yang bertujuan untuk mengurangi *overfitting* (Yong et al., 2023).

Tabel 3. Parameter Arsitektur MobileNetV2

Layer (Tipe)	Output Shape	Parameter
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dense (Dense)	(None, 128)	163,968
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 4)	516
Total		2,422,468

Model yang digunakan pada tabel 3 merupakan arsitektur *MobileNetV2* dengan total sekitar 2,42 juta parameter dan ukuran model kurang lebih 9,2 MB, pada bagian awal yaitu memuat model *MobileNetV2* pretrained dengan imagenet, lalu menghapus layer, selanjutnya mengizinkan layer pada *MobileNetV2* untuk ikut dilatih kembali, kemudian melakukan fine tuning dengan membekukan sebagian layer dan hanya melatih 40 layer terakhir. Pendekatan ini menjaga efisiensi komputasi sekaligus memberikan kapasitas yang cukup untuk membedakan empat kategori tingkat kematangan pisang.

Tabel 4. Konfigurasi Pelatihan

Parameter	Nilai/Pengaturan
Arsitektur Input	224 x 224 pixel (RGB)
Batch Size	32
Optimizer	Adam
Learning Rate	1e-6
Epochs	50
Patience (Early Stopping)	10 Epochs

Proses pelatihan dilakukan dalam tiga fase utama, yaitu fase ekstraksi fitur, reduksi fitur, dan klasifikasi. Pada fase pertama, citra masukan diproses menggunakan backbone *MobileNetV2* untuk mengekstraksi fitur warna dan tekstur melalui rangkaian layer konvolusi yang efisien. Selanjutnya pada fase kedua, layer *GlobalAveragePooling2D* digunakan untuk merangkum feature map menjadi vektor fitur yang lebih ringkas sehingga mengurangi jumlah parameter dan meningkatkan efisiensi model. Pada fase terakhir, proses klasifikasi dilakukan menggunakan beberapa layer *fully connected* yang terdiri dari *Dense layer*, *Dropout* untuk mengurangi *overfitting*, serta layer output dengan fungsi aktivasi *softmax* yang menghasilkan probabilitas prediksi untuk empat kelas tingkat kematangan pisang. Selain itu juga menggunakan mekanisme *EarlyStopping* dengan patience sepuluh epoch yang memonitor nilai *validation loss* yang dikombinasikan dengan *ReduceLROnPlateau* dengan faktor penurunan 0,2 dan patience tiga epoch, serta *ModelCheckpoint* untuk menyimpan model dengan akurasi terbaik sehingga proses pelatihan berjalan lebih stabil dan efisien.

2.6 Evaluation

Penelitian ini menggunakan *confusion matrix* dan *classification repor* sebagai acuan utama dalam evaluasi model. *Confusion matrix* merupakan alat analisis berbentuk tabel yang menampilkan empat kemungkinan hasil dari proses klasifikasi, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)* (Lie et al., 2026). Pendekatan ini digunakan untuk menilai tingkat performa model dengan membandingkan label data yang sebenarnya dengan hasil prediksi yang dihasilkan oleh model. Hasil perbandingan tersebut selanjutnya digunakan untuk menghitung sejumlah metrik evaluasi, antara lain *accuracy*, *precision*, *recall*, serta *F1-score* (Algiffary & Sutabri, 2023). Selanjutnya, hasil perhitungan dari metrik-metrik tersebut dirangkum dalam bentuk *classification report*. Rumus yang digunakan untuk menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score* dapat dilihat pada persamaan (1), (2), (3), dan (4).

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

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1-score = 2 \times \frac{recall \times precision}{recall + precision} \quad (4)$$

2.7 Deployment

Integrasi model ke dalam sistem aplikasi merupakan tahap penting dalam siklus pengembangan *machine learning* agar hasil prediksi dapat dimanfaatkan secara langsung oleh pengguna. Pada tahap ini, model *TensorFlow (.h5)* yang telah di

train sebelumnya akan dikonversi ke format *TensorFlow Lite (.tflite)* agar proses inferensi dapat berjalan lebih efisien untuk perangkat seluler yang memiliki komputasi terbatas (Pamungkas et al., 2026). Setelah proses konversi selesai, tahap integrasi model dan pengembangan antarmuka aplikasi dilakukan menggunakan Android Studio, di mana model tersebut diimplementasikan menggunakan bahasa pemrograman Kotlin hingga terbentuk sebuah aplikasi yang bisa digunakan untuk melakukan prediksi tingkat kematangan pisang.


3. HASIL DAN PEMBAHASAN

Pada tahap pelatihan model untuk memprediksi kematangan pisang, data terbagi menjadi empat kategori, yaitu *unripe*, *ripe*, *overripe*, dan *rotten*. Dalam proses ini dilakukan perbandingan performa model menggunakan tiga jenis optimizer serta satu skenario tanpa optimizer. Penggunaan optimizer antara lain yaitu *Adam*, *SGD*, dan *RMSProp* dengan menerapkan mekanisme *callback* berupa *early stopping* dan *model checkpoints*. Penerapan *early stopping* dengan nilai *patience* 10 yang bertujuan untuk mengurangi *overfitting* dengan menghentikan proses pelatihan apabila nilai *validation loss* tidak mengalami perbaikan selama 10 epoch berturut-turut. Sementara itu, *model checkpoints* digunakan untuk menyimpan model terbaik berdasarkan nilai *validation accuracy*. Rincian percobaan yang dilakukan ditampilkan pada Tabel 5.

Tabel 5. Hasil Perbandingan Optimizer

Optimizer	Batch Size	Epoch	Early Stopping	Train Accuracy	Val Accuracy	Test Accuracy
No optimizer	32	50	25 Epoch	99,44%	98,58%	98,75%
Adam	32	50	23 Epoch	99,60%	98,75%	99,47%
SGD	32	50	23 Epoch	99,36%	98,31%	98,93%
RMSProp	32	50	31 Epoch	99,70%	98,75%	98,93%

Berdasarkan hasil perbandingan Tabel 5 menunjukkan performa pelatihan model menggunakan beberapa variasi optimizer, yaitu tanpa optimizer tambahan (*baseline*), *Adam*, *SGD*, dan *RMSProp*, dengan parameter pelatihan yang sama berupa *batch size* sebesar 32 serta penerapan mekanisme *early stopping* untuk mencegah terjadinya *overfitting* selama proses pelatihan. Berdasarkan hasil yang ditampilkan, seluruh konfigurasi model dapat mencapai level ketepatan yang luar biasa, yakni melebihi 99% pada data pelatihan. Model dengan optimizer *RMSProp* menghasilkan nilai akurasi pelatihan tertinggi sebesar 99,70%, diikuti oleh *Adam* dengan 99,60%, konfigurasi tanpa optimizer tambahan sebesar 99,44%, dan *SGD* dengan 99,36%. Pada evaluasi data validasi, optimizer *Adam* dan *RMSProp* menunjukkan performa yang stabil dengan nilai akurasi sebesar 98,75%, sedangkan konfigurasi tanpa optimizer tambahan menghasilkan akurasi 98,58% dan *SGD* sebesar 98,31%. Sementara itu, pada pengujian menggunakan dataset test, model dengan optimizer *Adam* memperoleh performa terbaik dengan akurasi sebesar 99,47%, diikuti oleh konfigurasi tanpa optimizer tambahan sebesar 98,75%, serta *SGD* dan *RMSProp* yang masing-masing menghasilkan akurasi 98,93%. Selain itu, proses pelatihan juga menunjukkan perbedaan jumlah epoch saat *early stopping* terjadi, di mana optimizer *Adam* dan *SGD* berhenti pada epoch ke-23, konfigurasi tanpa optimizer pada epoch ke-25, dan *RMSProp* pada epoch ke-31. Secara keseluruhan, hasil perbandingan ini menunjukkan bahwa penggunaan optimizer *Adam* memberikan keseimbangan terbaik antara akurasi pelatihan, validasi, dan pengujian, sehingga dipilih sebagai konfigurasi yang paling optimal untuk digunakan dalam pengembangan model prediksi tingkat kematangan pisang.



Gambar 4. History Training dan Validation

Grafik pada Gambar 4 menunjukkan performa pelatihan model yang meliputi metrik akurasi (*accuracy*) dan nilai kehilangan (*loss*) selama proses pelatihan (*training*) dan validasi (*validation*) pada setiap epoch. Grafik ini digunakan

untuk menganalisis bagaimana model belajar dari data serta untuk mengevaluasi stabilitas dan kualitas proses *training*. Grafik *Model Accuracy*, terlihat bahwa *training accuracy* mengalami kenaikan dengan cukup baik di beberapa epoch awal. Nilai akurasi awal yang berada pada kisaran 0,92 meningkat dengan cepat hingga mendekati 1,00 setelah beberapa epoch pertama, kemudian cenderung stabil hingga akhir proses pelatihan. Peningkatan yang cepat pada fase awal menunjukkan bahwa model dapat mempelajari pola fundamental dari data pelatihan dengan efektif. Setelah mencapai nilai akurasi yang tinggi, kurva *training accuracy* menjadi lebih stabil, yang menandakan bahwa model telah mencapai kondisi konvergensi dan tidak mengalami perubahan performa yang signifikan pada epoch berikutnya. Fenomena yang serupa juga terlihat pada grafik *validation accuracy*. Pada epoch awal, nilai akurasi validasi berada pada kisaran 0,72, yang kemudian mengalami peningkatan drastis hingga menyentuh lebih dari 0,97 hanya dalam beberapa epoch. Setelah itu, nilai akurasi validasi cenderung stabil pada rentang 0,98 hingga 0,99 hingga akhir proses *training*. Pola peningkatan yang relatif konsisten antara *training accuracy* dan *validation accuracy* memperlihatkan berhasil memahami pola-pola yang ada dalam data pelatihan, tetapi juga dapat menggeneralisasikan pengetahuan tersebut secara efektif di data validasi. Stabilitas nilai akurasi validasi pada epoch-epoch akhir juga memperlihatkan bahwa model telah berhasil mendapatkan performa yang optimal tanpa mengalami penurunan performa yang signifikan.

Berdasarkan grafik Model Loss, dapat diamati bahwa nilai training loss menunjukkan kecenderungan menurun secara stabil sepanjang proses pelatihan model. Pada beberapa epoch awal, nilai loss masih berada pada kisaran 0,24, namun secara bertahap terus berkurang hingga hampir mencapai 0 pada epoch terakhir. Penurunan ini menandakan bahwa kesalahan prediksi yang dihasilkan oleh model semakin kecil seiring bertambahnya jumlah epoch pelatihan. Hal tersebut menunjukkan bahwa model semakin mampu menyesuaikan bobot dan parameter internalnya sehingga nilai fungsi kerugian (loss function) dapat diminimalkan selama proses pembelajaran berlangsung. Tren serupa juga terlihat pada grafik validation loss yang memperlihatkan penurunan nilai yang cukup signifikan. Pada epoch pertama, nilai validation loss tercatat sekitar 1,27, yang mengindikasikan bahwa pada tahap awal pelatihan model masih mengalami tingkat kesalahan yang cukup tinggi ketika melakukan prediksi pada data validasi. Namun, seiring dengan berjalannya proses pelatihan, nilai tersebut menurun secara signifikan hingga mencapai sekitar 0,08 pada epoch terakhir. Meskipun pada beberapa epoch di tengah proses pelatihan terjadi fluktuasi kecil, secara keseluruhan nilai validation loss tetap memperlihatkan pola penurunan yang konsisten. Fluktuasi ringan tersebut merupakan kondisi yang umum terjadi pada proses pelatihan model deep learning dan tidak menunjukkan adanya gangguan atau permasalahan yang berarti pada proses pembelajaran model.

Korelasi yang serupa antara kurva *training loss* serta *validation loss* memperlihatkan bahwa model tidak mengalami indikasi *overfitting*, sebagaimana bisa dilihat di Tabel 5. Dalam kondisi *overfitting*, biasanya nilai training loss akan terus menurun secara signifikan karena model terlalu menyesuaikan diri terhadap data pelatihan, sementara nilai *validation loss* justru meningkat tajam akibat menurunnya kemampuan model dalam melakukan generalisasi. Namun, pada grafik yang diperoleh dalam penelitian ini, kedua kurva menunjukkan pola perubahan yang relatif stabil dan searah selama proses pelatihan berlangsung. Hal tersebut mengindikasikan bahwa model mampu mempertahankan keseimbangan antara proses pembelajaran dari data pelatihan dan kemampuan dalam mengenali pola pada data baru yang belum pernah dipelajari sebelumnya. Hal ini ditunjukkan oleh peningkatan nilai akurasi yang tinggi serta penurunan nilai loss yang berlangsung secara konsisten sepanjang proses pelatihan. Kondisi tersebut membuktikan model berhasil mengeksplorasi pola dan karakteristik visual dari dataset dengan baik. Selain itu, kestabilan nilai akurasi dan loss pada data validasi juga menandakan model memiliki kemampuan generalisasi yang cukup baik, sehingga mampu memberikan performa klasifikasi yang optimal dalam tugas prediksi tingkat kematangan pisang.



Gambar 5. Hasil Prediksi pada Dataset Test

Gambar 5 memperlihatkan contoh hasil pengujian model terhadap beberapa citra pada dataset test (*test dataset*) yang bertujuan untuk menilai kinerja model dalam memprediksi tingkat kematangan pisang. Pada setiap citra ditampilkan dua informasi, yaitu label T (True) yang menunjukkan label sebenarnya dari data uji dan label P (Prediction) yang merupakan hasil prediksi yang dihasilkan oleh model. Berdasarkan hasil yang ditampilkan, model mampu mengklasifikasikan setiap citra pisang sesuai dengan tingkat kematangannya secara tepat. Citra pertama diklasifikasikan sebagai unripe, yang ditandai dengan warna kulit pisang yang masih hijau. Citra kedua diprediksi sebagai ripe, yang menunjukkan kondisi pisang matang dengan warna kuning cerah. Citra ketiga dikategorikan sebagai overripe, yang ditandai dengan munculnya bercak hitam pada kulit pisang sebagai indikasi tingkat kematangan lanjut.


Sementara itu, citra keempat diklasifikasikan sebagai rotten, yang menunjukkan kondisi pisang yang telah mengalami pembusukan dengan perubahan warna yang lebih gelap dan tekstur yang tidak lagi segar. Kesesuaian antara label *ground truth* dan prediksi model pada seluruh sampel citra mengindikasikan bahwa model berhasil mempelajari perbedaan pola visual pada tiap kategori kematangan pisang. Dengan demikian, model dapat melakukan klasifikasi secara tepat bahkan pada data pengujian yang belum pernah dipakai dalam proses pelatihan sebelumnya.

Tabel 6. Hasil Evaluasi Model

Label	Precision	Recall	F1-Score	Support
Unripe	0.99	1.00	1.00	110
Ripe	0.99	1.00	1.00	154
Overripe	1.00	0.99	1.00	185
Rotten	0.99	0.99	0.99	185
Accuracy			0.99	562
Macro avg	0.99	1.00	0.99	562
Weighted avg	0.99	0.99	0.99	562

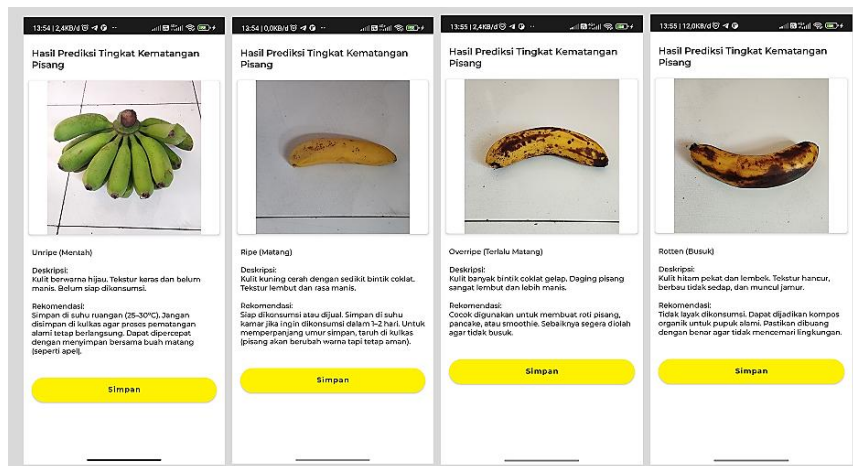
Tabel 6 menyajikan hasil evaluasi kinerja model dalam mengklasifikasikan tingkat kematangan pisang berdasarkan analisis confusion matrix. Evaluasi tersebut melibatkan beberapa metrik utama, yaitu precision, recall, F1-score, dan support untuk setiap kelas pada dataset pengujian. Nilai precision menggambarkan keakuratan model dalam melakukan prediksi pada suatu kelas, yaitu rasio antara total prediksi yang benar dengan keseluruhan prediksi yang dilakukan untuk kelas tersebut. Di sisi lain, recall mencerminkan seberapa efektif model dalam menemukan semua data yang tepat dalam sebuah kategori. Sedangkan F1-score adalah rata-rata antara precision dan recall yang berfungsi untuk menggambarkan keseimbangan kinerja model secara keseluruhan. Metrik support menunjukkan jumlah data pengujian yang tersedia pada masing-masing kelas. Berdasarkan hasil evaluasi yang ditampilkan pada tabel tersebut, model memberikan performa yang maksimal dalam mengklasifikasikan seluruh kategori kematangan pisang. Pada kelas unripe, model memperoleh nilai precision sebesar 0,99, recall sebesar 1,00, dan F1-score sebesar 1,00 dengan jumlah data uji sebanyak 110 sampel. Nilai recall yang mencapai 1,00 menunjukkan bahwa seluruh citra pisang mentah pada dataset pengujian berhasil dikenali dengan benar oleh model. Pada kelas ripe, model juga memberikan performa yang unggul yang mendapatkan nilai precision 0,99, recall 1,00, serta F1-score 1,00 dari total 154 sampel, yang membuktikan model sangat efektif dalam mengidentifikasi pisang yang telah matang.

Pada kelas overripe, model menghasilkan nilai precision 1,00, recall 0,99, dan 1,00 untuk F1-score dengan jumlah data uji sebanyak 113 sampel. Nilai precision yang mencapai 1,00 menunjukkan bahwa hampir seluruh prediksi yang dihasilkan pada kelas ini benar, meskipun terdapat sejumlah kecil data yang tidak teridentifikasi sehingga nilai recall sedikit lebih rendah. Sementara itu, pada kelas rotten, nilai *precision*, *recall*, dan *F1-score* semua memperoleh sebesar 0,99 dari total 185 sampel. Perolehan ini membuktikan dapat memprediksi pisang busuk dengan keakuratan yang tinggi meskipun masih terdapat sedikit kesalahan prediksi. Secara keseluruhan, model menghasilkan nilai accuracy sebesar 0,99 pada total 562 data pengujian, yang menunjukkan bahwa model mampu melakukan klasifikasi dengan tingkat ketepatan sekitar 99%. Selain itu, nilai macro average untuk *precision*, *recall*, dan *F1-score* masing-masing ialah 0,99, 1,00, dan 0,99, yang menunjukkan bahwa performa model relatif merata pada setiap kelas tanpa adanya perbedaan performa yang signifikan antar kategori. Nilai weighted average yang juga mencapai 0,99 menunjukkan bahwa kinerja model tetap stabil ketika mempertimbangkan proporsi jumlah data pada setiap kelas. Hasil classification report yang tertera, dapat diartikan bahwa model mempunyai kemampuan klasifikasi sangat baik untuk menyeleksi tingkat kematangan pisang berdasarkan karakteristik visual citra.



Gambar 6. Confusion Matrix

Confusion matrix pada Gambar 6 digunakan untuk evaluasi performa model dalam mengklasifikasikan tingkat kematangan pisang pada dataset pengujian. Confusion matrix memperlihatkan perbandingan antara label sebenarnya dengan hasil prediksi model untuk setiap kelas, yaitu *overripe*, *ripe*, *rotten*, dan *unripe*. Nilai yang terdapat pada garis diagonal utama mencerminkan total prediksi yang tepat, sementara nilai di luar garis diagonal menggambarkan kesalahan dalam pengelompokan yang terjadi. Berdasarkan hasil tersebut, sebagian besar data pengujian berhasil diklasifikasikan dengan tepat oleh model. Pada kelas *overripe*, sebanyak 112 sampel diprediksi dengan benar dan hanya 1 sampel yang keliru diklasifikasikan sebagai *rotten*. Pada kelas *ripe*, seluruh 154 sampel berhasil diprediksi secara tepat tanpa kesalahan. Untuk kelas *rotten*, model mampu mengidentifikasi 183 sampel dengan benar, meskipun terdapat masing-masing 1 sampel yang salah diprediksi sebagai *ripe* dan *unripe*. Sementara itu, pada kelas *unripe*, seluruh 110 sampel berhasil dikenali dengan benar. Dominasi nilai pada diagonal utama menunjukkan bahwa model memiliki performa klasifikasi yang unggul untuk membedakan tingkat kematangan pisang berdasarkan karakteristik visual citra. Jumlah kesalahan prediksi yang sangat kecil dibandingkan total data pengujian juga membuktikan bahwa model mempunyai tingkat akurasi tinggi serta kemampuan adaptasi yang baik terhadap data baru.



Gambar 7. Hasil Test pada Data Baru

Hasil pengujian yang ditampilkan pada Gambar 7 menunjukkan implementasi sistem prediksi tingkat kematangan pisang pada aplikasi mobile dengan menggunakan citra baru yang diperoleh dari kondisi nyata (*real-world data*). Data tersebut tidak termasuk dalam dataset pelatihan maupun dataset pengujian yang digunakan sebelumnya. Pengujian ini digunakan untuk mengevaluasi sejauh mana model dapat adaptasi pada data yang belum dikenal sebelumnya selama tahap pelatihan. Pada tampilan aplikasi ditunjukkan empat contoh hasil prediksi yang merepresentasikan masing-masing kategori tingkat kematangan pisang, yaitu *unripe*, *ripe*, *overripe*, dan *rotten*. Setiap hasil prediksi juga dilengkapi dengan informasi tambahan berupa deskripsi karakteristik fisik buah serta rekomendasi penanganan atau pemanfaatan buah berdasarkan tingkat kematangannya. Sebagai contoh, pisang dengan prediksi *unripe* ditandai oleh warna kulit yang masih hijau dengan tekstur buah yang relatif keras. Sementara itu, pisang dengan kategori *ripe* memiliki warna kuning cerah yang menunjukkan bahwa buah telah siap untuk dikonsumsi. Pada kategori *overripe*, terlihat adanya bercak coklat pada permukaan kulit pisang yang menandakan tingkat kematangan lanjut, meskipun buah tersebut masih dapat dimanfaatkan sebagai bahan olahan makanan. Adapun pada kategori *rotten*, pisang menunjukkan perubahan warna yang lebih gelap serta tekstur yang lembek sehingga tidak lagi layak untuk dikonsumsi. Hasil pengujian menggunakan citra dari kondisi nyata ini menyatakan sistem dapat mengenali tingkat kematangan pisang dengan efektif meskipun data yang digunakan berasal dari lingkungan yang berbeda dengan dataset pelatihan. Hal ini membuktikan model mempunyai kemampuan generalisasi yang baik serta dapat diterapkan secara efektif dalam aplikasi mobile untuk membantu petani dalam mengidentifikasi tingkat kematangan buah pisang secara lebih akurat.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilaksanakan, dapat ditarik kesimpulan bahwa penggunaan metode *Deep Learning* dengan memanfaatkan arsitektur *MobileNetV2* yang dioptimalkan menggunakan optimizer *Adam* mampu menghasilkan performa yang sangat baik saat proses klasifikasi tingkat kematangan pisang. Model yang dikembangkan sukses mengelompokkan buah pisang ke dalam empat kategori kematangan, yaitu *unripe*, *ripe*, *overripe*, dan *rotten* dengan tingkat akurasi mencapai 99,47%. Hasil evaluasi model memperlihatkan bahwa nilai *accuracy*, *precision*, *recall*, dan *F1-score* pada setiap kategori berada pada kisaran yang mendekati nilai optimal, yang membuktikan model mampu mengidentifikasi perbedaan karakteristik fisik dari setiap tingkat kematangan pisang secara efektif. Setelah proses pelatihan selesai, model selanjutnya diubah ke dalam format *TensorFlow Lite* (*.tflite*) sehingga bisa diterapkan pada perangkat seluler. Model tersebut selanjutnya diintegrasikan ke dalam aplikasi mobile yang dikembangkan menggunakan bahasa pemrograman Kotlin melalui platform Android Studio. Hasil implementasi menunjukkan bahwa aplikasi mampu menjalankan proses inferensi secara real-time dengan performa yang efisien pada perangkat seluler.



Selain menampilkan hasil prediksi tingkat kematangan pisang, sistem yang dikembangkan juga menyediakan informasi tambahan berupa deskripsi kondisi fisik buah serta rekomendasi penanganan yang sesuai dengan tingkat kematangannya. Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Sistem yang dikembangkan hanya mampu mengidentifikasi tingkat kematangan pisang berdasarkan karakteristik umum, yaitu perubahan warna kulit dari hijau menjadi kuning yang kemudian diikuti munculnya bercak coklat atau hitam sebagai tanda proses pembusukan. Sistem ini belum mampu mengenali beberapa varietas pisang yang memiliki karakteristik warna kulit yang berbeda, seperti jenis pisang yang tetap berwarna hijau saat matang atau varietas yang memiliki warna kulit kemerahan. Selain itu, model yang dikembangkan dalam penelitian ini hanya difokuskan pada klasifikasi kematangan buah pisang, sehingga belum dapat diterapkan untuk mendeteksi tingkat kematangan pada jenis buah lainnya. Untuk pengembangan di masa mendatang, sistem ini masih memiliki peluang peningkatan yang cukup luas. Penelitian selanjutnya dapat memperluas cakupan dataset dengan menambahkan variasi jenis pisang yang memiliki karakteristik warna kulit yang berbeda serta kondisi pencahayaan yang lebih beragam, sehingga model memiliki kemampuan generalisasi yang lebih baik. Selain itu, pengembangan model juga dapat diarahkan pada klasifikasi tingkat kematangan berbagai jenis buah lainnya, sehingga sistem dapat dimanfaatkan secara lebih luas dalam bidang pertanian maupun dalam proses distribusi dan pengelolaan hasil pangan.

REFERENCES

- Adão, T., Gonzalez, D., Castilla, Y. C., Pérez, J., Shahrabadi, S., Sousa, N., Guevara, M., & Magalhães, L. G. (2022). Using deep learning to detect the presence/absence of defects on leather: On the way to build an industry-driven approach. *Journal of Physics: Conference Series*, 2224(1). <https://doi.org/10.1088/1742-6596/2224/1/012009>
- Akay, M., Du, Y., Sershen, C. L., Wu, M., Chen, T. Y., Mohan, C., Akay, Y. M., & Member, S. (2021). *Deep Learning Classification of Systemic Sclerosis Skin using the MobileNetV2 Model*. <https://doi.org/10.1109/OJEMB.2021.3066097>
- Algiffary, A., & Sutabri, T. (2023). Indonesian Journal of Computer Science. *Indonesian Journal of Computer Science*, 12(2), 284–301. <http://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3135>
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep learning models for digital image processing: a review. In *Artificial Intelligence Review* (Vol. 57, Issue 1). Springer Netherlands. <https://doi.org/10.1007/s10462-023-10631-z>
- Baglat, P., Hayat, A., Mendonça, F., Gupta, A., Mostafa, S. S., & Morgado-Dias, F. (2023). Non-Destructive Banana Ripeness Detection Using Shallow and Deep Learning: A Systematic Review. *Sensors*, 23(2), 1–20. <https://doi.org/10.3390/s23020738>
- BPS. (2025). *Produksi Tanaman Buah–Buahan dan Sayuran Tahunan Menurut Jenis Tanaman, 2024*. 10 June. <https://www.bps.go.id/assets/statistics-table/3/WXpSVU5uUTBOSEI5WVhGQmVESTVSVnBSVlhWeVVUMDkjMw%3D%3D/produksi-tanaman-buah---buahan-dan-sayuran-tahunan-menurut-jenis-tanaman--2024.html?year=2024>
- Chamseddine, E., Mansouri, N., Soui, M., & Abed, M. (2022). Handling class imbalance in COVID-19 chest X-ray images classification: Using SMOTE and weighted loss. *Applied Soft Computing*, 129(February 2023). <https://doi.org/10.1016/j.asoc.2022.109588>
- Chaowalittawi, V., Krungseanmuang, O., Sathaporn, P., Morita, F., Archevapanich, T., & Purahong, B. (2025). Banana quality classification using lightweight CNN model with microservice integration system. *Engineering and Applied Science Research*, 431.
- Chuquimarca, L. E., Vintimilla, B. X., & Velastin, S. A. (2025). Assessing deep learning model robustness for banana ripeness classification under varying illumination conditions. *Smart Agricultural Technology*, 12(August), 101333. <https://doi.org/10.1016/j.atech.2025.101333>
- Hadhiwibowo, A., Asri, S. R., & Dinata, R. A. (2024). *Penerapan Convolutional Neural Network dengan Arsitektur Mobilenetv2 Pada Aplikasi Penerjemah dan Pembelajaran Bahasa Isyarat TIN : Terapan Informatika Nusantara*. 4(8), 518–523. <https://doi.org/10.47065/tin.v4i8.4879>
- Hanifah, A. I., & Hermawan, A. (2023). Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network. *Komputika : Jurnal Sistem Komputer*, 12(2), 49–56. <https://doi.org/10.34010/komputika.v12i2.9999>
- Irawati, A. R., Kurniawan, D., Utami, Y. T., & Taufik, R. (2024). An Exploration of TensorFlow-Enabled Convolutional Neural Network Model Development for Facial Recognition: Advancements in Student Attendance System. *Scientific Journal of Informatics*, 11(2), 413–428. <https://doi.org/10.15294/sji.v11i2.3585>
- Kosasih, R. (2021). Klasifikasi Tingkat Kematangan Pisang Berdasarkan Ekstraksi Fitur Tekstur dan Algoritma KNN. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 10(4), 383–388.
- Lie, J., Rahman, A., & Udjulawa, D. (2026). *TIN : Terapan Informatika Nusantara Klasifikasi Penyakit Daun Kentang Berbasis CNN MobileNetV2 dengan Optimasi Randomize Search TIN : Terapan Informatika Nusantara*. 6(9), 1598–1607. <https://doi.org/10.47065/tin.v6i9.9108>
- Pamungkas, A. S., Triono, J. M., Pinesthi, E., Utomo, W., & Paramita, C. (2026). *TIN : Terapan Informatika Nusantara Implementasi MobileNetV2 pada Aplikasi Mobile untuk Penilaian Objektif Kondisi Fisik Ponsel Bekas TIN : Terapan Informatika Nusantara*. 6(9), 1726–1736. <https://doi.org/10.47065/tin.v6i9.8947>
- Pangestu, A., Purnama, B., & Risnandar, R. (2024). Vision Transformer untuk Klasifikasi Kematangan Pisang. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 11(1), 75–84. <https://doi.org/10.25126/jtiik.20241117389>



- Rafi, M., Firdaus, A., Mardhiyyah, R., & Sanjaya, F. I. (2025). *TIN : Terapan Informatika Nusantara Klasifikasi Citra Biji Kopi Sangrai Arabika dan Robusta Menggunakan Convolutional Neural Network TIN : Terapan Informatika Nusantara*. 6(7), 969–980. <https://doi.org/10.47065/tin.v6i7.8695>
- Simanjuntak, J. M., & Muhathir. (2025). JITE (Journal of Informatics and Telecommunication Engineering) Application of MobileNetV2 Architecture with SIMAM For Automatic Detection of Diseases on Mango Leaves. *Jite*, 8(3), 9. <https://doi.org/10.31289/jite.v8i3Spc.14612>
- Wicaksono, A. D. (2023). Klasifikasi Tingkat Kematangan, Kualitas dan Jenis Buah Pisang Berdasarkan Ciri Warna dan Bentuk Menggunakan Artificial Neural Networks. *Jurnal Teknologi Informasi Indonesia (JTII)*, 7(2), 91–98. <https://doi.org/10.30869/jtii.v7i2.955>
- Yong, L., Ma, L., Sun, D., & Du, L. (2023). Application of MobileNetV2 to waste classification. *PLoS ONE*, 18(3 March), 1–16. <https://doi.org/10.1371/journal.pone.0282336>
- Yu, F., Xiu, X., & Li, Y. (2022). A Survey on Deep Transfer Learning and Beyond. *Mathematics*, 10(19), 1–27. <https://doi.org/10.3390/math10193619>
- Zhu, L., & Huang, L. (2022). A Resource Scheduling Method for Enterprise Management Based on Artificial Intelligence Deep Learning. *Mobile Information Systems*, 2022. <https://doi.org/10.1155/2022/4277149>