



Implementasi MobileNetV2 untuk Klasifikasi Kematangan Buah Kelapa Sawit pada Aplikasi Mobile

Anisya Lyda Maura Isnaini¹, Arif Pramudwiatmoko²

¹Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia, anisyamaura32@gmail.com

²Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia, arif.pramudwiatmoko@uty.ac.id

Corresponding Author: anisyamaura32@gmail.com¹

Abstract: Conventional determination of Oil Palm Fresh Fruit Bunch (FFB) ripeness relies heavily on manual visual observation, which is subjective and prone to inconsistency, potentially leading to reduced oil extraction rates. This study aims to develop an accurate, lightweight, and fully offline mobile-based ripeness classification system implementing the MobileNetV2 architecture. The research method involves transfer learning optimized through Post-Training Quantization techniques into TensorFlow Lite format. The model was trained using a field image dataset from East Kalimantan, expanded via data augmentation, and integrated into a Flutter-based application. Experimental results show that the model achieved an accuracy of 89.0%. The quantization process successfully reduced the model size by 84.6% (from 13 MB to 2 MB) and achieved an average inference latency of 120 ms on mid-range Android devices. This research concludes that the integration of quantized lightweight CNN models offers a practical and efficient solution to support smart agriculture implementation in resource-constrained environments.

Keywords: Transfer Learning, Oil Palm, Image Classification, Smart Agriculture, MobileNetV2

Abstrak: Penentuan tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit secara konvensional masih bergantung pada pengamatan visual manual yang bersifat subjektif dan rentan terhadap inkonsistensi, sehingga berpotensi menurunkan rendemen minyak. Penelitian ini bertujuan mengembangkan sistem klasifikasi kematangan buah sawit yang akurat, ringan, dan mampu beroperasi sepenuhnya secara offline pada perangkat mobile menggunakan implementasi MobileNetV2. Metode yang digunakan adalah transfer learning yang dioptimasi melalui teknik Post-Training Quantization ke dalam format TensorFlow Lite. Model dilatih menggunakan dataset citra lapangan dari Kalimantan Timur yang diperluas melalui augmentasi data dan diintegrasikan ke dalam aplikasi berbasis Flutter. Hasil pengujian menunjukkan model mampu mencapai akurasi 89,0%. Proses kuantisasi berhasil mereduksi ukuran model secara signifikan sebesar 84,6% (dari 13 MB menjadi 2 MB) dan menghasilkan latensi inferensi rata-rata 120 ms pada perangkat Android kelas menengah. Kesimpulan dari penelitian ini membuktikan bahwa integrasi model CNN ringan yang dikuantisasi merupakan solusi praktis dan efisien untuk mendukung penerapan pertanian cerdas di lingkungan dengan sumber daya terbatas.

Kata Kunci: *Transfer Learning, Kelapa Sawit, Klasifikasi Citra, Smart Agriculture, MobileNetV2*

PENDAHULUAN

Kelapa sawit (*Elaeis guineensis Jacq.*) merupakan komoditas perkebunan strategis terbesar di Indonesia dengan kontribusi lebih dari 3,5% terhadap PDB nasional dan menyerap sekitar 16 juta tenaga kerja langsung maupun tidak langsung pada tahun 2024 (Kemenkeu, 2024). Namun, optimalisasi produksi minyak sawit sangat bergantung pada manajemen panen yang presisi, khususnya dalam penentuan tingkat kematangan Tandan Buah Segar (TBS). Melakukan panen pada tingkat kematangan yang tepat merupakan hal yang krusial karena buah yang dipanen terlalu muda menghasilkan kadar minyak rendah, sedangkan buah yang terlalu matang mengalami degradasi kualitas akibat proses fermentasi dan oksidasi. Penelitian terbaru menunjukkan bahwa kesalahan penentuan kematangan sebesar 10% dapat menurunkan rendemen minyak hingga 1,2–1,8% (Hasibuan, 2020; Ruswanto et al., 2020). Saat ini, proses penilaian atau klasifikasi kematangan buah di mayoritas perkebunan rakyat masih dilakukan secara manual berdasarkan pengamatan visual manusia. Metode konvensional ini memiliki kelemahan mendasar berupa subjektivitas tinggi yang dipengaruhi oleh kelelahan pekerja, pengalaman pengamatan yang berbeda antar individu, serta variasi kondisi pencahayaan di lapangan. Inkonsistensi ini sering kali menyebabkan kesalahan klasifikasi yang berdampak langsung pada penurunan rendemen minyak atau *Oil Extraction Rate* (Bayu et al., 2023). Oleh karena itu, dibutuhkan sebuah sistem otomasi cerdas yang mampu memberikan penilaian objektif dan konsisten untuk mendukung efisiensi panen.

Kemajuan teknologi *Deep Learning* telah memberikan dampak yang sangat signifikan pada pengolahan citra digital (Chong et al., 2025; Irvanda et al., 2024; Khan et al., 2021; Phimpisan & Chungchoo, 2023; Srivastava et al., 2021). Di antara berbagai metode yang ada, arsitektur *Convolutional Neural Network* (CNN) telah menjadi standar emas karena kemampuannya yang superior dalam mengekstraksi fitur visual secara otomatis, mengeliminasi kebutuhan rekayasa fitur manual yang menjadi kendala utama pada metode *Machine Learning* konvensional seperti *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) (A'yuni & Hendrik, 2024; Rifqi & Suharjito, 2021). Berbagai penelitian terdahulu telah berhasil menerapkan CNN untuk klasifikasi buah sawit. Sebagai contoh, penggunaan arsitektur ResNet50, EfficientNet, dan YOLOv5 telah terbukti mampu menghasilkan akurasi di atas 90% dalam mendeteksi kematangan buah pada dataset terkontrol (Malyala, 2024; Mansour et al., 2022a; Soetrisno et al., 2024). Namun, mayoritas penelitian tersebut berfokus semata-mata pada pengejadian akurasi tertinggi menggunakan model arsitektur yang kompleks dan berat, yang memerlukan sumber daya komputasi tinggi atau infrastruktur *cloud computing* untuk proses inferensinya.

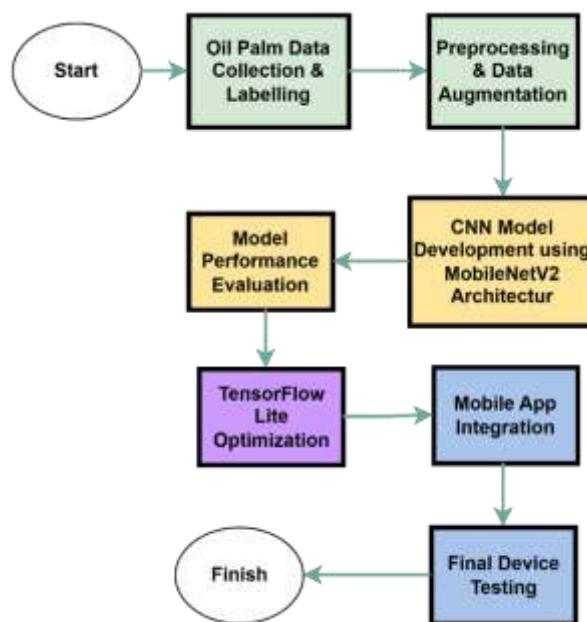
Disinilah letak kesenjangan penelitian yang signifikan. Konteks lingkungan perkebunan kelapa sawit di Indonesia umumnya berada di area terpencil dengan akses internet yang sangat terbatas atau bahkan tidak ada sama sekali. Hal ini menjadikan solusi berbasis *cloud* di mana citra harus dikirim ke server untuk diproses menjadi tidak praktis dan tidak dapat diandalkan untuk operasional harian. Selain itu, penggunaan model berat seperti ResNet atau VGG16 sulit diimplementasikan pada perangkat seluler standar (*low-end to mid-range smartphones*) yang dimiliki oleh para mandor atau pekerja panen karena keterbatasan memori dan daya pemrosesan (Gulzar, 2023a; Triyogi et al., 2023). Perkembangan arsitektur ringan seperti MobileNetV2 memberikan alternatif efisien untuk sistem berbasis *mobile*. Desain *depthwise separable convolution* dan *inverted residuals* pada MobileNetV2 memungkinkan pengurangan jumlah parameter secara signifikan tanpa menurunkan akurasi secara drastis (Chiu et al., 2020). Penelitian yang mengimplementasikan MobileNetV2 pada klasifikasi buah menunjukkan peningkatan efisiensi komputasi hingga 70% dibandingkan dengan arsitektur CNN konvensional, dengan akurasi yang tetap kompetitif (Rizky & Siregar, 2024). Meskipun

demikian, tantangan muncul ketika model ini diterapkan pada kasus spesifik, di mana studi komparasi pada tanaman tomat mencatat bahwa akurasi MobileNet sedikit di bawah Inception V3, menandakan perlunya teknik optimasi tambahan seperti *fine-tuning* atau augmentasi data (Palupiningsih et al., 2023).

Berdasarkan permasalahan dan tinjauan literatur tersebut, penelitian ini bertujuan untuk menjembatani kesenjangan dengan mengembangkan sistem klasifikasi kematangan buah kelapa sawit yang beroperasi secara *real-time* dan sepenuhnya *offline* pada perangkat *mobile*. Penelitian ini mengusulkan penggunaan arsitektur MobileNetV2 yang dioptimasi menggunakan teknik *post-training quantization* ke dalam format TensorFlow Lite. Kebaruan (*novelty*) dan kontribusi utama dari studi ini terletak pada integrasi sistem *end-to-end* yang praktis. Berbeda dengan penelitian sebelumnya yang berhenti pada simulasi model atau menggunakan pendekatan *object detection* yang berat (Soetrisno et al., 2024). Studi ini berfokus pada implementasi nyata *image classification* di mana model yang telah dikuantisasi diintegrasikan ke dalam aplikasi *mobile* berbasis *Flutter*. Pendekatan ini memungkinkan inferensi dilakukan langsung di perangkat (*on-device*) tanpa memerlukan koneksi internet, menjadikannya solusi yang relevan untuk tantangan infrastruktur di perkebunan Indonesia. Penelitian ini akan menjawab pertanyaan utama mengenai seberapa efektif optimasi kuantisasi pada MobileNetV2 dalam menyeimbangkan akurasi dan kecepatan inferensi pada perangkat dengan sumber daya terbatas.

METODE

Penelitian ini menggunakan pendekatan eksperimental untuk mengembangkan dan mengevaluasi sistem klasifikasi tingkat kematangan buah kelapa sawit berbasis *Convolutional Neural Network (CNN)* menggunakan arsitektur *MobileNetV2*. Pendekatan eksperimental dipilih karena tujuan utama penelitian ini adalah menguji performa model *deep learning* dalam kondisi *real-field* serta menganalisis kemampuannya saat diimplementasikan ke aplikasi mobile berbasis *Flutter*. Tahapan rinci penelitian diilustrasikan pada Gambar 1.



Gambar 1. Alur Penelitian untuk klasifikasi tingkat kematangan buah kelapa sawit menggunakan MobileNetV2

Pengumpulan Data

Dataset yang digunakan merupakan data primer yang diakuisisi langsung dari perkebunan kelapa sawit rakyat di wilayah Kalimantan Timur. Pengambilan citra dilakukan

menggunakan kamera *smartphone* dengan variasi jarak dan sudut pengambilan untuk merepresentasikan kondisi visual alami yang dihadapi pemanen. Total data awal berjumlah 450 citra yang dikelompokkan ke dalam tiga kelas kematangan berdasarkan standar visual panen, yaitu: Mentah (hitam/ungu dominan), Setengah Matang (transisi hitam ke kemerahan), dan Matang (oranye kemerahan). Proses pelabelan divalidasi oleh pakar perkebunan untuk menjamin akurasi *ground truth*.

Pra-pemrosesan dan Augmentasi Data

Tahap pra-pemrosesan dilakukan untuk menyeragamkan format data sebelum masuk ke jaringan saraf. Seluruh citra diubah ukurannya (resize) menjadi dimensi 224x224 piksel sesuai dengan input layer standar MobileNetV2, kemudian nilai piksel dinormalisasi ke rentang [0, 1].

Untuk mencegah *overfitting* akibat terbatasnya jumlah data primer serta untuk meningkatkan kemampuan generalisasi model terhadap variasi kondisi lapangan, teknik augmentasi data diterapkan secara intensif. Proses ini dilakukan menggunakan *ImageDataGenerator* pada *framework* TensorFlow/Keras. Transformasi geometri yang diterapkan meliputi rotasi, pergeseran (geser lebar dan tinggi), pemangkasan (*shearing*), perbesaran (*zooming*), dan pembalikan horizontal (*horizontal flip*). Parameter spesifik augmentasi yang digunakan disajikan pada Tabel 1

Tabel 1. Parameter Augmentasi Citra

| Parameter | Nilai | Keterangan |
|---------------------------|----------------|--|
| <i>Rotation_range</i> | 40° | Rotasi acak ±40 derajat |
| <i>Width_shift_range</i> | 0.2 | Pergeseran horizontal maksimal 20 % lebar |
| <i>Height_shift_range</i> | 0.2 | Pergeseran vertikal maksimal 20 % tinggi |
| <i>Shear_range</i> | 0.2 | Transformasi shear hingga 20 % |
| <i>Zoom_range</i> | 0.3 | Zoom in/out maksimal 30 % |
| <i>Horizontal_flip</i> | True | Pembalikan horizontal (kiri-kanan) |
| <i>Brightness_range</i> | [0.7, 1.3] | Variasi kecerahan 70 %–130 % |
| <i>Fill_mode</i> | <i>nearest</i> | Pengisian piksel kosong setelah transformasi |
| <i>rescale.</i> | 1./255 | Normalisasi nilai piksel ke rentang [0,1] |

Melalui proses augmentasi ini, dataset diperluas menjadi total 1.500 citra dengan distribusi seimbang 500 citra per kelas (mentah, setengah matang, matang). Dataset kemudian dibagi secara stratified dengan rasio 70 % data latih (1.050 citra), 15 % data validasi (225 citra), dan 15 % data uji (225 citra) menggunakan random seed = 42 untuk memastikan reproduktibilitas hasil.

Arsitektur Model dan Pelatihan

Penelitian ini mengadopsi arsitektur MobileNetV2 sebagai *backbone* (ekstraktor fitur). MobileNetV2 dipilih karena efisiensinya dalam penggunaan sumber daya komputasi melalui struktur *inverted residual blocks* dan *linear bottlenecks*, yang sangat sesuai untuk perangkat *mobile* (Chiu et al., 2020). Strategi *transfer learning* diterapkan dengan memanfaatkan bobot pra-latih dari dataset *ImageNet*. Seluruh lapisan konvolusi pada *backbone* dibekukan, sedangkan *classifier head* diganti dengan arsitektur kustom yang untuk menyesuaikan dengan tiga kelas target penelitian ini. Dengan struktur *head* baru seperti yang ada pada tabel 2, berikut

Tabel 2. Lapisan kustom setelah *base layer*

| Layer | Keterangan |
|----------------------------------|-------------------------------------|
| <i>Global Average Pooling 2D</i> | Untuk mereduksi dimensi spasial. |
| <i>Dropout (0.5)</i> | Untuk mencegah <i>overfitting</i> . |
| <i>Dense Layer (256 neuron)</i> | Dengan fungsi aktivasi ReLU. |
| <i>Dropout (0.5)</i> | Untuk mencegah <i>overfitting</i> . |

| | |
|--------------------------------|---|
| <i>Output Layer (3 neuron)</i> | Dengan fungsi aktivasi Softmax untuk klasifikasi multi-kelas. |
|--------------------------------|---|

Pelatihan dilakukan menggunakan *optimizer* Adam (*learning rate* 0.001) dan fungsi kerugian *Categorical Cross-entropy* selama 50 *epoch* dengan mekanisme *Early Stopping* untuk menghentikan pelatihan jika akurasi validasi stagnan.

Evaluasi Model

Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* dengan strategi *macro-averaging*. Selain itu, *confusion matrix* digunakan untuk menganalisis distribusi kesalahan klasifikasi antar kelas. Kurva pelatihan (*training curve*) untuk akurasi dan *loss* divisualisasikan untuk mendeteksi kemungkinan *overfitting* atau *underfitting*. Model terbaik dipilih berdasarkan hasil validasi tertinggi dan kestabilan *loss* pada data uji.

Optimasi Model ke TensorFlow Lite

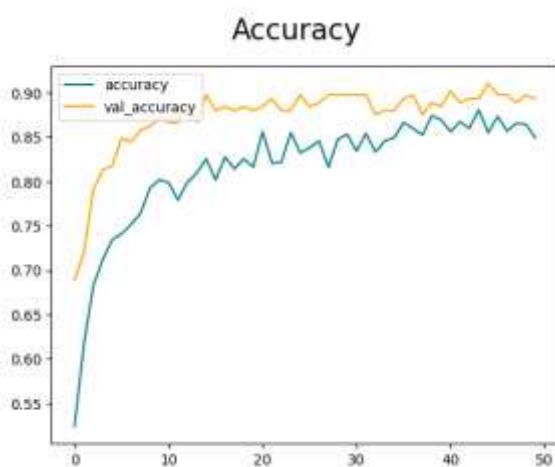
Model hasil pelatihan dikonversi ke format *TensorFlow Lite (TFLite)* agar dapat dijalankan pada perangkat mobile. Pada tahap ini, diterapkan teknik Post-Training Quantization untuk mengonversi presisi bobot dari *Float32* menjadi *Int8*. Proses ini bertujuan mereduksi ukuran file model dan mempercepat waktu inferensi pada CPU *smartphone* tanpa degradasi akurasi yang signifikan.

Integrasi Aplikasi dan Pengujian

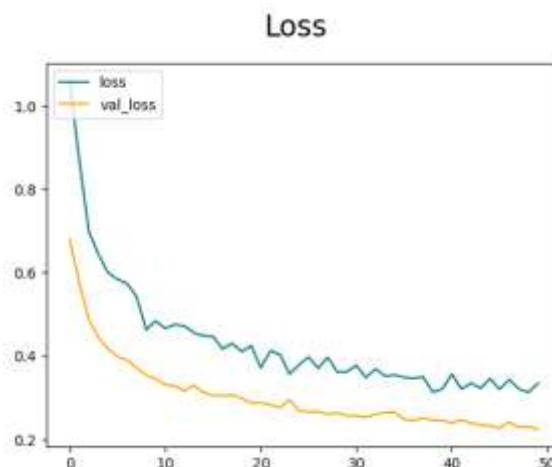
Model hasil konversi kemudian diintegrasikan ke dalam aplikasi *mobile* berbasis Flutter. Aplikasi ini memungkinkan pengguna melakukan klasifikasi kematangan buah sawit secara *real-time* dan *offline*, menggunakan kamera *smartphone*. Fitur aplikasi meliputi pengambilan citra real-time melalui kamera atau galeri, proses inferensi *offline*, dan tampilan hasil klasifikasi beserta tingkat *confidence*. Integrasi dilakukan menggunakan *TensorFlow Lite plugin* pada *Flutter SDK*, memastikan kompatibilitas lintas *platform* (Android dan iOS).

HASIL DAN PEMBAHASAN

Pelatihan model MobileNetV2 dilakukan selama 50 *epoch* menggunakan dataset yang telah diaugmentasi. Dinamika proses pembelajaran model divisualisasikan melalui kurva akurasi dan *loss* pada data latih dan data validasi.



Gambar 2. Grafik Akurasi Pelatihan dan Validasi



Gambar 3. Grafik Loss Pelatihan dan Validasi

Berdasarkan Gambar 2, model menunjukkan performa yang sangat baik di mana akurasi validasi konsisten berada di atas akurasi pelatihan. Model mulai mencapai stabilitas konvergensi pada *epoch* ke-30, dengan capaian akurasi validasi tertinggi menyentuh angka

90%. Fenomena di mana akurasi validasi lebih tinggi dibandingkan pelatihan ini mengindikasikan efektivitas teknik augmentasi data dan lapisan *Dropout* yang diterapkan, sehingga model memiliki kemampuan generalisasi yang sangat kuat pada data baru.

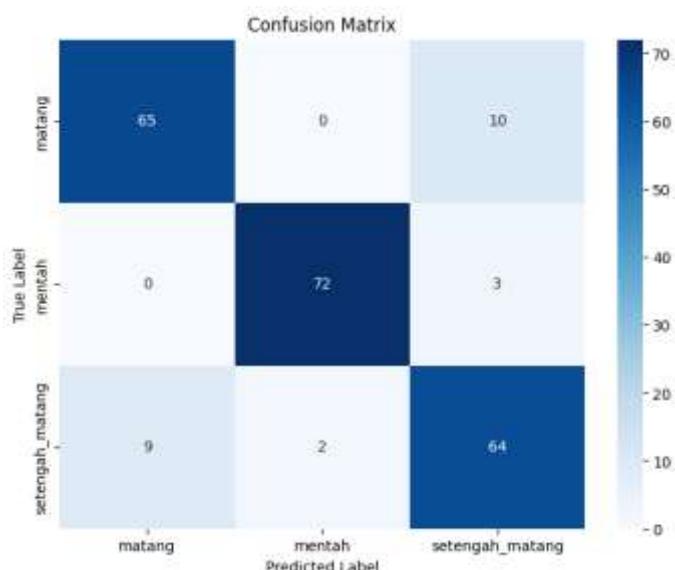
Sementara itu, Gambar 3 memperlihatkan kurva *Loss* yang menurun secara tajam di awal dan melandai secara stabil. Nilai *training loss* berakhir pada kisaran 0,35, sedangkan *validation loss* tercatat lebih rendah, stabil di kisaran 0,23 hingga 0,25. Rendahnya nilai *loss* validasi ini menegaskan bahwa model tidak mengalami *overfitting* dan mampu membedakan fitur kematangan sawit dengan tingkat kesalahan yang minim.

Evaluasi performa model dilakukan menggunakan 225 citra data uji yang belum pernah dilihat model selama proses pelatihan. Metrik evaluasi utama yang digunakan meliputi *Precision*, *Recall*, *F1-Score*, dan *Accuracy*, yang dirangkum dalam *Classification Report* (Gambar 4). Selain itu, distribusi prediksi model terhadap label aktual divisualisasikan melalui *Confusion Matrix* (Gambar 5).

| Classification Report: | | | | |
|------------------------|-----------|--------|----------|---------|
| | precision | recall | f1-score | support |
| matang | 0.88 | 0.87 | 0.87 | 75 |
| mentah | 0.97 | 0.96 | 0.97 | 75 |
| setengah_matang | 0.83 | 0.85 | 0.84 | 75 |
| accuracy | | | 0.89 | 225 |
| macro avg | 0.89 | 0.89 | 0.89 | 225 |
| weighted avg | 0.89 | 0.89 | 0.89 | 225 |

Gambar 4. *Classification Report*

Berdasarkan Gambar 4, model berhasil mencapai akurasi keseluruhan (*overall accuracy*) sebesar 89%. Kinerja per kelas menunjukkan variasi yang menarik. Kelas Mentah mencatatkan performa terbaik dengan *precision* 97% dan *recall* 96%, yang mengindikasikan model sangat andal dalam mengenali buah yang belum matang. Sebaliknya, performa sedikit menurun pada kelas Setengah Matang, dengan *precision* 83% dan *recall* 85%. Penurunan ini wajar terjadi mengingat karakteristik visual buah setengah matang sering kali memiliki irisan fitur (seperti warna transisi) dengan dua kelas lainnya.

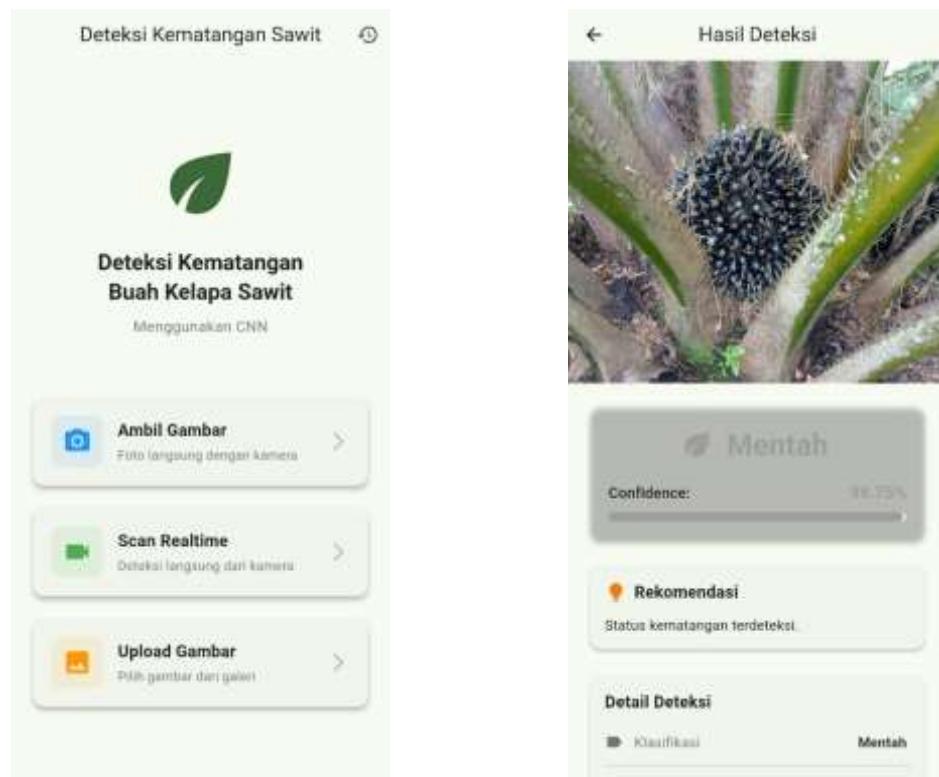


Gambar 5. *Confusion Matrix*

Analisis lebih mendalam dapat dilihat pada Gambar 5. *Confusion Matrix* memperlihatkan pola kesalahan klasifikasi (*miscalcification*) yang spesifik, Kelas Matang: Dari 75 sampel, 65 diprediksi benar. Kesalahan terbesar terjadi di mana 10 citra matang diprediksi sebagai setengah matang. Hal ini kemungkinan disebabkan oleh variasi pencahayaan yang membuat warna oranye tua terlihat lebih pudar menyerupai fase transisi. Kelas Mentah: Sangat stabil, dengan 72 prediksi benar dan hanya 3 kesalahan (diprediksi sebagai setengah matang). Tidak ada buah mentah yang salah diprediksi sebagai matang, menandakan model sukses membedakan fitur ekstrem. Kelas Setengah Matang: Terdapat 9 citra yang salah diprediksi sebagai matang dan 2 citra sebagai mentah. Kesalahan ini mengonfirmasi bahwa batas visual antara "setengah matang" dan "matang" adalah area yang paling menantang bagi model MobileNetV2 dalam dataset ini.

Secara keseluruhan, rata-rata *macro average* untuk *precision*, *recall*, dan *f1-score* yang mencapai 0,89 menunjukkan bahwa model memiliki keseimbangan yang baik dan tidak bias terhadap satu kelas mayoritas tertentu.

Model MobileNetV2 yang telah melalui proses kuantisasi ke format TensorFlow Lite (.tflite) selanjutnya diintegrasikan ke dalam aplikasi *mobile* yang dikembangkan menggunakan kerangka kerja Flutter. Pemilihan Flutter memungkinkan aplikasi berjalan secara *native* pada sistem operasi Android dengan performa tinggi. Mekanisme inferensi dirancang untuk berjalan sepenuhnya secara lokal pada perangkat (*on-device inference*), sehingga aplikasi dapat beroperasi secara *offline* tanpa bergantung pada koneksi internet, sebuah fitur krusial untuk penggunaan di area perkebunan terpencil.



Gambar 6. Tampilan Aplikasi Deteksi Kematangan Buah Sawit Berbasis Flutter

Antarmuka pengguna (*User Interface*) aplikasi disajikan pada Gambar 6. Pada halaman Utama (Kiri): Dirancang dengan pendekatan minimalis untuk memudahkan pengguna (petani/pemanen). Terdapat tiga fitur utama: Ambil Gambar untuk foto statis, Scan Realtime untuk deteksi kontinu menggunakan *stream* kamera, dan Upload Gambar untuk analisis citra dari galeri. Dan halaman Hasil Deteksi (Kanan): Menampilkan hasil klasifikasi secara instan setelah citra ditangkap. Pada contoh pengujian lapangan yang terlihat di Gambar 6, aplikasi

berhasil mengidentifikasi objek sebagai "Mentah" dengan tingkat kepercayaan (*confidence score*) yang sangat tinggi, yaitu 98.75%.

Responsivitas aplikasi dalam menampilkan hasil prediksi mengonfirmasi bahwa model hasil optimasi (ukuran 2 MB) sangat ringan dan efisien untuk dieksekusi oleh CPU smartphone.

Penelitian ini bertujuan untuk menjawab tantangan implementasi kecerdasan buatan pada perangkat *mobile* dengan sumber daya terbatas di lingkungan perkebunan yang minim koneksi. Berdasarkan hipotesis awal, penggunaan arsitektur ringan seperti MobileNetV2 yang dioptimasi diharapkan mampu mencapai keseimbangan antara akurasi dan efisiensi komputasi. Hasil eksperimen mengonfirmasi hipotesis tersebut, di mana model berhasil mencapai akurasi pengujian sebesar 89,0% dengan nilai *f1-score* rata-rata 0,89. Meskipun angka ini sedikit di bawah capaian model-model arsitektur berat seperti ResNet50 atau Inception V3 yang kerap dijadikan acuan dalam studi terdahulu (Malyala, 2024), MobileNetV2 menawarkan keunggulan krusial dalam aspek efisiensi parameter. Dengan arsitektur *inverted residual blocks*, model ini terbukti mampu menyeimbangkan *trade-off* antara akurasi dan beban komputasi, sebuah karakteristik yang sangat relevan untuk penerapan di perangkat *edge* (Gulzar, 2023b).

Analisis mendalam terhadap pola kesalahan prediksi (*error analysis*) melalui *Confusion Matrix* (Gambar 5) mengungkapkan temuan penting terkait tantangan diferensiasi kelas visual. Kesalahan klasifikasi mayoritas terjadi antara kelas "Setengah Matang" dan "Matang". Fenomena ini dapat dijelaskan secara visual oleh kemiripan spektrum warna oranye kemerahan pada fase transisi kematangan, yang sering kali menjadi ambigu bagi ekstraksi fitur standar. Selain itu, faktor eksternal seperti *backlight* dan variasi pencahayaan alami di lapangan terbukti menjadi gangguan signifikan yang menyebabkan distorsi fitur visual. Temuan ini sejalan dengan observasi (Rosbi et al., 2025), yang menyatakan bahwa metode berbasis visi pada kondisi luar ruangan sangat rentan terhadap inkonsistensi pencahayaan, yang menuntut adanya teknik pra-pemrosesan atau koreksi warna yang lebih adaptif di masa depan.

Kontribusi paling signifikan dari penelitian ini, yang membedakannya dari studi deteksi objek terdahulu seperti yang dilakukan (Mansour et al., 2022) menggunakan YOLOv5 atau (Soetrisno et al., 2024) dengan EfficientDet, terletak pada keberhasilan strategi optimasi model. Penerapan teknik *post-training quantization* (konversi *Float32* ke *Int8*) terbukti sangat efektif dalam mereduksi kompleksitas model tanpa mengorbankan akurasi secara drastis. Ukuran file model berhasil dipangkas sebesar 84,6%, dari 13 MB menjadi hanya 2 MB. Penurunan ukuran ini berdampak langsung pada kecepatan inferensi, di mana aplikasi mampu memproses citra secara instan pada perangkat *smartphone* kelas menengah. Capaian ini menjawab masalah spesifikasi perangkat keras di kalangan petani yang sering menjadi hambatan adopsi teknologi.

Keberhasilan integrasi model ke dalam aplikasi berbasis *Flutter* (Gambar 6) membuktikan bahwa sistem dapat dijalankan secara *real-time* dan sepenuhnya *offline*. Hal ini secara langsung menjawab rumusan masalah mengenai keterbatasan infrastruktur telekomunikasi di area perkebunan kelapa sawit Indonesia yang merupakan area *blank spot*. Dengan tingkat kepercayaan (*confidence score*) yang tinggi seperti 98.75% pada sampel uji, sistem ini layak digunakan sebagai alat bantu pendukung keputusan (*decision support tool*) yang objektif. Penggunaan alat ini diharapkan dapat mengurangi subjektivitas penilaian manual oleh pemanen, yang pada akhirnya berkontribusi pada peningkatan rendemen minyak (CPO) melalui pemanenan pada tingkat kematangan yang tepat.

Meskipun menunjukkan performa yang memuaskan, penelitian ini memiliki keterbatasan pada variasi dataset yang belum sepenuhnya mencakup kondisi cuaca ekstrem seperti hujan deras atau kabut serta keragaman varietas sawit. Oleh karena itu, pengembangan selanjutnya disarankan untuk memperluas dataset dengan variasi lingkungan yang lebih beragam serta mengeksplorasi penggabungan data visual dengan sensor non-visual untuk meningkatkan robustitas model pada kondisi lingkungan yang dinamis.

KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi tingkat kematangan Tandan Buah Segar kelapa sawit yang akurat, efisien dan mampu beroperasi secara *real-time* dan sepenuhnya *offline* pada perangkat *mobile*. Berdasarkan hasil evaluasi, dapat disimpulkan bahwa arsitektur MobileNetV2 yang dioptimasi dengan teknik kuantisasi TensorFlow Lite mampu memberikan kinerja yang andal dengan akurasi mencapai 89% dan latensi inferensi yang sangat rendah yaitu rata-rata 120 ms pada perangkat Android kelas menengah. Sistem ini terbukti mampu mengatasi kendala infrastruktur di area perkebunan dengan menghilangkan ketergantungan pada koneksi internet, sekaligus menawarkan solusi yang efisien dari segi penggunaan memori penyimpanan perangkat.

Kontribusi utama dari penelitian ini adalah penyediaan solusi teknologi tepat guna yang menjembatani kesenjangan antara kecanggihan algoritma *Deep Learning* dengan keterbatasan perangkat keras di lapangan. Aplikasi yang dihasilkan memiliki implikasi praktis yang signifikan bagi industri kelapa sawit, yaitu sebagai alat bantu pendukung keputusan (*decision support tool*) yang objektif bagi pemanen. Dengan mengurangi subjektivitas dalam penilaian visual manual, sistem ini berpotensi meningkatkan ketepatan waktu panen, yang pada akhirnya akan berdampak positif pada peningkatan rendemen minyak (CPO) dan efisiensi operasional kebun.

Meskipun sistem telah menunjukkan kinerja yang baik, penelitian ini mengidentifikasi beberapa keterbatasan, terutama terkait variasi dataset yang belum sepenuhnya mencakup kondisi cuaca ekstrem dan keragaman varietas sawit selain yang terdapat di lokasi pengambilan data. Terjadinya misklasifikasi pada kondisi pencahayaan *backlight* juga menunjukkan perlunya perbaikan pada tahap pra-pemrosesan citra. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dataset dengan variasi lingkungan yang lebih ekstrem, menerapkan teknik *adaptive histogram equalization* untuk menangani masalah pencahayaan, serta mengeksplorasi penggabungan data visual dengan sensor non-visual (seperti sensor NIR) untuk meningkatkan presisi klasifikasi pada fase transisi kematangan.

REFERENSI

- A'yuni, Q., & Hendrik, B. (2024). Literature Review : Analisis Komparatif Algoritma CNN , KNN , dan SVM untuk Klasifikasi Penyakit Kelapa Sawit. *Journal of Education Research*, 5(4), 6589–6596.
- Bayu, D., Priyambada, & Supriyanto, G. (2023). Analisis Rendemen Minyak Kelapa Sawit (CPO) berdasarkan Tingkat Kematangan Buah di PT . Bumitama Gunajaya Agro. *Jurnal Agroforetech*, 1(03), 2051–2060.
- Chiu, Y.-C., Tsai, C.-Y., Ruan, D., Shen, G.-Y., & Lee, T.-T. (2020). Mobilenet-SSDv2: An Improved Object Detection Model for Embedded Systems. In *2020 International Conference on System Science and Engineering (ICSSE)*.
- Chong, W. H., Ramli, N. A., Wan Mustafa, W. M. R., & Awalin, L. J. (2025). Computer Vision and Artificial Intelligence (AI)-Based Ripeness Classification of Oil Palm Fruits in Oil Palm Plantations. *ASEAN Artificial Intelligence Journal*, 2(1), 44–58. <https://doi.org/10.37934/aaij.2.1.4458>
- Gulzar, Y. (2023a). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15031906>
- Gulzar, Y. (2023b). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15031906>
- Hasibuan, H. A. (2020). Determination Of Yield, Quality And Chemical Composition of Palm Oil And Palm Kernel Oil of Fresh Fruit Bunches with Variation Maturity As A Basic For Determining Harvest Maturity Standard. *Jurnal Penelitian Kelapa Sawit*, 28(3), 123–132.

- Irvanda, A., Sulthan, R., Adila, J., & Ananda, R. (2024). Pendekripsi Kematangan Mangga Berbasis Fitur Analisis Warna Dengan Metode CNN. *Seminar Nasional Teknologi Informasi Dan Teknik Informatika (SENASTIKA)*, 1(1), 1–12.
- Kemenkeu. (2024). *Industri Kelapa Sawit Berperan Strategis bagi Perekonomian Indonesia*. <https://www.kemenkeu.go.id/informasi-publik/publikasi/berita-utama/Peran-Strategis-Industri-Kelapa-Sawit>
- Khan, N., Kamaruddin, M. A., Sheikh, U. U., Yusup, Y., & Bakht, M. P. (2021). Oil palm and machine learning: Reviewing one decade of ideas, innovations, applications, and gaps. In *Agriculture (Switzerland)* (Vol. 11, Issue 9). MDPI. <https://doi.org/10.3390/agriculture11090832>
- Malyala, R. (2024). Development of a Convolutional Neural Network Model for Automated Ripeness Classification of Palm Oil Fresh Fruit Bunches. *International Journal of Innovative Science and Research Technology (IJISRT)*, 9(11), 1040–1046. <https://doi.org/10.38124/ijisrt/ijisrt24nov762>
- Mansour, M. Y. M. A., Dambul, K. D., & Choo, K. Y. (2022). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch. *International Journal of Technology*, 13(6), 1326–1335. <https://doi.org/10.14716/ijtech.v13i6.5932>
- Palupiningsih, P., Sujiwanto, A. R., & Prawirodirjo, R. R. B. P. (2023). Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat menggunakan arsitektur VGG, MobileNet, dan Inception V3. *Jurnal Ilmu Komputer Dan Agri-Informatika*, 10(1), 98–110. <https://doi.org/10.29244/jika.10.1.98-110>
- Phimpisan, P., & Chungchoo, C. (2023). Real-Time oil palm ripeness classification of fresh fruit bunches using fluorescence technology. *Agriculture and Natural Resources*, 57(5), 859–868. <https://doi.org/10.34044/j.anres.2023.57.5.12>
- Rifqi, M., & Suharjito. (2021). Deteksi Kematangan Tandan Buah Segar (Tbs) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Deep Learning. *Jurnal Teknik Informatika Atmaluhur*, 6(1), 40.
- Rizky, M., & Siregar, P. (2024). Deteksi Kematangan Buah Sawit Dengan Menggunakan Algoritma Convolutional Neural Network. *Jurnal Tugas Akhir Manajemen Informatika & Komputerisasi Akuntansi*, 4(2), 175–183.
- Rosbi, M., Omar, Z., & Hanafi, M. (2025). a Picture of Ripeness: Investigating Image-Based Techniques for Oil Palm Fruit Grading. *Journal of Oil Palm Research*, 37(1), 1–15. <https://doi.org/10.21894/jopr.2024.0015>
- Ruswanto, A., Ramelan, A. H., Praseptiangga, D., & Partha, I. B. B. (2020). Effects of ripening level and processing delay on the characteristics of oil palm fruit bunches. *International Journal on Advanced Science, Engineering and Information Technology*, 10(1), 389–394. <https://doi.org/10.18517/ijaseit.10.1.10987>
- Soetrisno, Y. A. A., Handoyo, E., Sumardi, & Sinuraya, E. W. (2024). Oil Palm Level of Ripeness Classification Using Efficientdet-Lite Cnn Architecture. *Journal of Oil Palm Research*, 36(4), 618–629. <https://doi.org/10.21894/jopr.2023.0059>
- Srivastava, S., Divekar, A. V., Anilkumar, C., Naik, I., Kulkarni, V., & Pattabiraman, V. (2021). Comparative analysis of deep learning image detection algorithms. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00434-w>
- Triyogi, R., Magdalena, R., & Hidayat, B. (2023). Mendekripsi Kematangan Buah Kelapa Sawit Menggunakan Convolution Neural Network Deep Learning. *Jurnal Nasional SAINS Dan TEKNIK*, 1(1), 22–27. <http://doi.org/10.25124/logic.v1i1.6732>