

KLASIFIKASI KEMATANGAN BUAH LOKAL KALIMANTAN MENGUNAKAN *TRANSFER LEARNING*

Nisa Puspita Sari¹, Dwi Wahyu Prabowo², Nurahman³

¹Program Studi Sistem Informasi, Universitas Darwan Ali, Jl. Batu Berlian No.10, Kabupaten Kotawaringin Timur, Kalimantan Tengah, Indonesia 74323

***Email korespondensi:** nisapuspitasari27@gmail.com

Received: 27 05 2026 – Revised: 29 07 2026 - Accepted: 04 08 2026 - Published: 05 08 2026

Abstrak.

Penentuan tingkat kematangan buah kelapa sawit merupakan salah satu faktor yang berpengaruh langsung terhadap mutu dan produktivitas hasil perkebunan. Pada praktiknya, identifikasi kematangan buah masih banyak mengandalkan pengamatan manusia, sehingga hasil penilaian rentan terhadap perbedaan persepsi antaroperator. Penelitian ini mengusulkan penerapan metode *transfer learning* untuk mengotomatisasi proses identifikasi tingkat kematangan buah kelapa sawit berbasis citra digital. Dua arsitektur *deep learning*, yaitu MobileNetV3-Large dan EfficientNet-B0, digunakan untuk membangun model klasifikasi sekaligus dianalisis performanya. Proses pelatihan memanfaatkan dataset Fruits-360 sebagai sumber pembelajaran awal fitur visual, kemudian dilakukan penyesuaian menggunakan dataset citra buah kelapa sawit yang mencakup tiga kelas tingkat kematangan, yaitu mentah, mengkal, dan matang. Sebelum pelatihan model dilakukan, seluruh citra diproses melalui tahap prapengolahan dan augmentasi untuk meningkatkan keragaman data serta mengurangi risiko *overfitting*. Kemampuan model dalam melakukan klasifikasi dinilai berdasarkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang diperoleh dari hasil pengujian. Hasil eksperimen menunjukkan bahwa kedua model mampu mengenali tingkat kematangan buah dengan baik. Namun demikian, EfficientNet-B0 menghasilkan performa yang lebih tinggi dengan nilai *accuracy* 92,31%, *precision* 92,86%, *recall* 92,86%, dan *F1-score* 92,20%. Sementara itu, MobileNetV3-Large memperoleh *accuracy* 79,49%, *precision* 82,94%, *recall* 80,30%, dan *F1-score* 79,58%. Temuan ini menunjukkan bahwa pendekatan *transfer learning* memiliki potensi yang kuat untuk mendukung pengembangan sistem identifikasi kematangan buah kelapa sawit secara otomatis, konsisten, dan efisien pada lingkungan perkebunan modern.

Kata kunci: Kematangan buah kelapa sawit, *Transfer Learning*, MobileNetV3, *TensorFlow Lite*, Pertanian Digital.

PENDAHULUAN

Sebagai komoditas perkebunan unggulan, kelapa sawit memiliki peran penting dalam mendukung perekonomian Indonesia melalui kontribusinya terhadap ekspor, penyerapan tenaga kerja, serta penyediaan bahan baku untuk berbagai industri pengolahan. Sebagai negara produsen minyak sawit terbesar di dunia, Indonesia memiliki area perkebunan yang tersebar luas di berbagai wilayah, salah satunya Kalimantan Tengah. Dalam pengolahan industri kelapa sawit, tingkat kematangan tandan buah segar (TBS) menjadi salah satu indikator penting yang menentukan kualitas bahan baku. Pemanenan yang dilakukan sebelum mencapai kematangan optimal dapat menyebabkan penurunan persentase perolehan minyak dari buah kelapa sawit. Sebaliknya, keterlambatan panen dapat menyebabkan peningkatan kandungan asam lemak bebas yang berdampak pada penurunan mutu minyak

sawit yang dihasilkan. Oleh karena itu, proses identifikasi kematangan buah menjadi tahapan yang sangat penting dalam rangka menjaga kualitas dan kuantitas produksi. Pada praktiknya, penilaian kematangan TBS di lapangan masih banyak bergantung pada pengamatan visual yang dilakukan oleh tenaga panen. Metode tersebut berpotensi menghasilkan ketidakkonsistenan karena dipengaruhi oleh faktor manusia, kondisi lingkungan, serta kemiripan karakteristik visual antar tingkat kematangan buah.

Kemajuan teknologi kecerdasan buatan, khususnya pada bidang *computer vision*, telah memberikan alternatif yang menjanjikan untuk mengotomatisasi proses identifikasi objek berbasis citra. Salah satu metode yang banyak diterapkan dalam pengolahan citra adalah Convolutional Neural Network (CNN). Arsitektur ini mampu mengenali dan mempelajari karakteristik visual dari data secara otomatis sehingga kebutuhan ekstraksi fitur secara manual dapat diminimalkan. Seiring dengan perkembangan teknologi deep learning, pendekatan transfer learning semakin banyak digunakan karena mampu memanfaatkan pengetahuan dari model yang telah dilatih pada dataset berskala besar. Melalui transfer learning, proses pelatihan dapat dilakukan dengan jumlah data dan waktu komputasi yang lebih rendah, tanpa mengurangi kemampuan model dalam mempelajari karakteristik baru pada data target (Howard et al., 2019; Tan & Le, 2019). Dalam konteks klasifikasi kematangan buah kelapa sawit, sejumlah penelitian menunjukkan bahwa penggunaan model prelatih dapat menghasilkan kinerja yang kompetitif. Penelitian terdahulu melaporkan bahwa penerapan *transfer learning* berbasis ImageNet yang dipadukan dengan teknik augmentasi citra mampu meningkatkan kemampuan model dalam membedakan tingkat kematangan tandan buah segar, dengan EfficientNet-B0 menghasilkan performa terbaik pada pengujian. Studi lain juga mengevaluasi beberapa arsitektur CNN dengan berbagai skenario pembagian data latih dan pengaturan *learning rate* untuk mengidentifikasi empat kategori kematangan buah kelapa sawit (Zulkarnain et al., 2024). Sementara itu (Soetrisno et al., 2024) memperkenalkan penggunaan *EfficientDet-Lite* sebagai alternatif arsitektur yang menunjukkan potensi untuk mendukung tugas klasifikasi pada domain yang serupa.

Sejumlah penelitian sebelumnya telah mengevaluasi kinerja *MobileNetV3-Large* dan EfficientNet-B0 pada berbagai permasalahan klasifikasi di sektor pertanian. Kedua arsitektur tersebut dilaporkan mampu menghasilkan tingkat akurasi yang tinggi pada identifikasi penyakit tanaman, seperti penyakit stroberi, jeruk, maupun padi (Pramudhita et al., 2023; Dianto et al., 2025). Pada penelitian yang dilakukan oleh (Naufal Abiyyu & Rahardi, 2026). *MobileNetV3-Large* memperoleh hasil pengujian yang sedikit lebih baik

dibandingkan *EfficientNet-B0* dalam klasifikasi enam kategori penyakit daun padi. Meskipun demikian, pemanfaatan kedua model tersebut untuk mengenali tingkat kematangan buah kelapa sawit masih belum banyak dilaporkan, terutama pada dataset yang berasal dari kondisi perkebunan lokal di Kalimantan. Keterbatasan tersebut menunjukkan adanya peluang untuk melakukan evaluasi lebih lanjut terhadap kemampuan kedua arsitektur dalam konteks yang berbeda. Berdasarkan kondisi tersebut, penelitian ini berfokus pada pengembangan sistem klasifikasi kematangan buah kelapa sawit berbasis *transfer learning* dengan memanfaatkan *MobileNetV3-Large* dan *EfficientNet-B0* sebagai model utama. Selanjutnya, performa kedua model dianalisis dan dibandingkan untuk mengetahui arsitektur yang paling efektif dalam mengenali perbedaan tingkat kematangan buah.

MASALAH

Penentuan waktu panen yang tepat merupakan salah satu faktor penting dalam pengelolaan perkebunan kelapa sawit karena berkaitan erat dengan produktivitas dan mutu minyak yang dihasilkan. Tingkat kematangan tandan buah segar (TBS) menjadi indikator utama yang digunakan untuk menentukan kelayakan panen. Dalam praktiknya, proses penilaian kematangan masih banyak mengandalkan pengamatan langsung oleh tenaga panen berdasarkan karakteristik visual buah, seperti perubahan warna kulit dan jumlah brondolan yang terlepas dari tandan. Pendekatan tersebut relatif sederhana untuk diterapkan, namun hasilnya sangat bergantung pada pengalaman dan ketelitian masing-masing pekerja. Berbagai faktor lapangan, seperti posisi tandan yang sulit diamati, kondisi pencahayaan yang berubah-ubah, serta keterbatasan sudut pandang saat pengamatan, dapat memengaruhi akurasi penilaian (Ahmed Mansour et al., 2023).


Permasalahan dalam penentuan tingkat kematangan buah kelapa sawit tidak hanya berkaitan dengan subjektivitas pengamat, tetapi juga dipengaruhi oleh keragaman karakteristik citra, seperti perbedaan kondisi pencahayaan, latar belakang, serta sudut pengambilan gambar. Studi yang membangun dataset citra dan video TBS dari pabrik kelapa sawit di Kalimantan Selatan menunjukkan bahwa kondisi nyata di lapangan latar belakang lantai semen pabrik, variasi pencahayaan, serta keragaman kategori kematangan buah membuat banyak dataset penelitian sebelumnya kurang merepresentasikan kondisi sesungguhnya (Suharjito et al., 2023). Variasi sudut pengambilan citra juga menjadi tantangan tersendiri, sehingga teknik augmentasi seperti *9 angle crop* telah diusulkan untuk meningkatkan ketahanan model CNN terhadap perubahan sudut pandang saat klasifikasi kematangan TBS (Suharjito et al., 2021). Kemiripan warna antara buah setengah matang dan

matang turut menyulitkan metode konvensional berbasis fitur warna sederhana, sehingga diperlukan pendekatan ekstraksi fitur yang lebih kompleks dan robust terhadap variasi kondisi lingkungan.

Kemajuan metode *deep learning*, terutama melalui pendekatan *transfer learning*, memberikan peluang untuk membangun sistem klasifikasi citra yang tetap memiliki performa tinggi meskipun jumlah data pelatihan relatif terbatas. Pemanfaatan model pralatih yang telah mempelajari karakteristik visual dari dataset berskala besar memungkinkan proses pembelajaran menjadi lebih efisien serta meningkatkan kemampuan model dalam mengenali pola pada data baru. Berdasarkan potensi tersebut, penelitian ini mengevaluasi dan membandingkan kinerja *MobileNetV3-Large* dan *EfficientNet-B0* dalam mengidentifikasi tingkat kematangan buah kelapa sawit dari citra digital guna memperoleh model yang paling akurat dan andal.

METODE PELAKSANAAN

Penelitian ini menggunakan pendekatan eksperimen dengan metode Transfer Learning untuk mengklasifikasikan tingkat kematangan buah kelapa sawit berdasarkan citra digital. Proses penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan dataset, preprocessing citra, augmentasi data, pembagian dataset, penerapan model, proses pelatihan, serta evaluasi kinerja model. Dua arsitektur deep learning yang digunakan dalam penelitian ini adalah MobileNetV3-Large dan EfficientNet-B0.



Gambar 1 Diagram Alur Penelitian

A. Pengumpulan Dataset

Penelitian ini menggunakan dua sumber dataset yang dikombinasikan secara strategis untuk mendukung strategi pelatihan dua fase. Dataset penelitian menggunakan

citra buah kelapa sawit yang diperoleh dari Mendeley Data dengan jumlah 254 citra yang terbagi menjadi tiga kategori kematangan, yaitu mentah, mengkal, dan matang. Selain dataset utama, digunakan pula subset *Fruits-360* sebagai data tambahan untuk membantu proses pembelajaran fitur awal. Seluruh citra dilakukan *preprocessing* dengan melakukan perubahan ukuran menjadi 224×224 piksel serta normalisasi berdasarkan standar *ImageNet*. Tahap *augmentation* diterapkan pada data pelatihan untuk memperluas variasi citra dengan menggunakan teknik *horizontal flip*, *vertical flip*, rotasi, *color jitter*, *gaussian blur*, *random shadow*, dan *grid distortion*.

B. Pembagian Dataset

Dataset kemudian dibagi dan dipisahkan menjadi tiga subset, yaitu data *training* sebesar 70%, *validation* sebesar 15%, dan *testing* sebesar 15%. Data *training* digunakan sebagai referensi untuk membuat model, data *validation* digunakan untuk untuk evaluasi performa model yang berkembang seiring berjalannya proses training dan juga untuk melakukan tuning parameter, misalnya *early stopping* guna menghindari *overfitting*. Sementara itu data *testing* digunakan untuk mengevaluasi kemampuan model dalam melakukan prediksi pada data yang tidak terlibat selama proses pelatihan. Skema pembagian ini diterapkan untuk memperoleh penilaian performa yang lebih objektif dan representatif terhadap kemampuan generalisasi model.


C. Implementasi Model

Proses implementasi model pada penelitian ini menggunakan pendekatan *transfer learning* dengan melakukan perbandingan terhadap dua arsitektur *deep learning* yaitu *MobileNetV3-Large* dan *EfficientNet-B0*. Kedua arsitektur tersebut memanfaatkan bobot awal (*pretrained weight*) yang telah didapat dari proses pelatihan pada dataset *ImageNet* sebagai dasar dalam proses ekstraksi fitur citra. Selanjutnya, bagian lapisan klasifikasi (*classifier*) pada setiap masing-masing model disesuaikan agar dapat menghasilkan hasil berupa tiga kategori tingkat kematangan buah kelapa sawit, yaitu mentah, mengkal, dan matang.

Pada tahap pelatihan model dilakukan melalui dua fase optimasi. Pada fase pertama, lapisan utama jaringan (*backbone*) dilakukan pembekuan (*freeze*) sehingga bobot fitur yang telah dipelajari sebelumnya tetap dipertahankan dan proses pembelajaran difokuskan pada bagian klasifikasi. Setelah model memperoleh parameter awal yang sesuai, fase berikutnya dilakukan dengan membuka kembali seluruh lapisan jaringan (*unfreeze*) dan menerapkan proses *fine-tuning*. Tahap ini bertujuan untuk menyesuaikan

parameter model agar mampu mengenali karakteristik serta pola visual yang terdapat pada dataset citra kelapa sawit.

Gambar 2 menunjukkan rancangan jaringan yang digunakan dalam penelitian ini. Kedua model, yaitu *MobileNetV3-Large* dan *EfficientNet-B0*, tidak dilatih dari awal, melainkan menggunakan parameter hasil pembelajaran sebelumnya pada dataset *ImageNet*. Citra masukan terlebih dahulu melewati beberapa lapisan pada jaringan utama untuk



memperoleh informasi penting berupa karakteristik visual. Hasil representasi tersebut kemudian dikirim ke bagian akhir jaringan (*classifier*) yang berfungsi menentukan label kelas berdasarkan tingkat kematangan buah kelapa sawit ke dalam tiga kelompok, yaitu mentah, mengkal, dan matang.

Pada algoritma *MobileNetV3-Large*, proses ekstraksi fitur dilakukan menggunakan operasi *convolution* dan *depthwise convolution*. Operasi konvolusi dapat dirumuskan sebagai berikut:

$$Y(i, j, k) = \sum_{m=1}^M \sum_{n=1}^N X(i + m, j + n) \times W(m, n, k) + b_k \quad (1)$$

Pada persamaan (1), $(Y(i, j, k))$ merupakan nilai fitur hasil konvolusi pada posisi (i, j) dan channel ke- (k) , yang diperoleh dari operasi antara nilai piksel citra masukan (X) dan bobot kernel (W), kemudian ditambahkan bias (b_k). Adapun (M) dan (N) menunjukkan ukuran kernel konvolusi yang digunakan.

Pada *MobileNetV3-Large*, proses *depthwise convolution* dilakukan dengan memproses setiap channel secara terpisah. Persamaan yang digunakan yaitu:

$$Y_k(i, j) = \sum_{m=1}^M \sum_{n=1}^N X_k(i + m, j + n) \times W_k(m, n) \quad (2)$$

Pada persamaan (2), (Y_k) menyatakan fitur keluaran pada channel ke- (k) yang dihasilkan dari proses konvolusi antara masukan (X_k) dan kernel (W_k) pada channel yang sama secara terpisah.

Setelah fitur berhasil diekstraksi, hasil tersebut diteruskan ke lapisan klasifikasi menggunakan fungsi *Softmax*:

$$P(y_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}} \quad (3)$$

Pada persamaan (3) Softmax, (P_i) menyatakan probabilitas kelas ke- (i) , (z_i) merupakan nilai keluaran neuron, dan (C) adalah jumlah kelas yang digunakan dalam proses klasifikasi.

Pada algoritma *EfficientNet-B0*, proses ekstraksi fitur menggunakan konsep *compound scaling* yang mengatur kedalaman jaringan (*depth*), lebar jaringan (*width*), dan resolusi citra (*resolution*) dengan persamaan (4),(5),(6):

$$D = \alpha^\phi \quad (4)$$

$$W = \beta^\phi \quad (5)$$

$$R = \gamma^\phi \quad (6)$$

dengan batasan:

$$\alpha \times \beta^2 \times \gamma^2 \approx 2 \quad (7)$$

Pada persamaan (7), (D) , (W) , dan (R) masing-masing menyatakan kedalaman jaringan, lebar jaringan, dan resolusi citra masukan. Adapun (α) , (β) , dan (γ) merupakan faktor penskalaan yang mengatur dimensi model, sedangkan (ϕ) berfungsi sebagai parameter pengendali skala. Hubungan antarparameter tersebut dibatasi oleh persamaan $(\alpha \times \beta^2 \times \gamma^2 \approx 2)$ untuk menjaga keseimbangan antara akurasi model dan efisiensi komputasi.

Pada proses ekstraksi fitur *EfficientNet-B0*, digunakan blok *Mobile Inverted Bottleneck Convolution* (MBConv), yang dapat direpresentasikan sebagai:

$$Y = \text{Conv}_{pw2} \left(SE \left(DWConv \left(\text{Conv}_{pw1}(X) \right) \right) \right) \quad (8)$$

Pada persamaan (8), (X) merupakan citra masukan yang diproses melalui pointwise convolution pertama (Conv_{pw1}), kemudian dilanjutkan dengan depthwise convolution

(*DWConv*) dan blok Squeeze and Excitation (*SE*) untuk meningkatkan representasi fitur. Selanjutnya, hasil proses tersebut diteruskan ke pointwise convolution kedua (*Conv_{pw2}*) sehingga menghasilkan fitur keluaran (*Y*).

Fitur hasil ekstraksi kemudian diteruskan ke lapisan klasifikasi dengan persamaan:

$$y^{\wedge} = Softmax(WX + b) \quad (9)$$

Pada persamaan (9), ($\hat{y}$) menunjukkan hasil prediksi kelas yang dihasilkan oleh model. Variabel (*W*) merupakan bobot pada lapisan klasifikasi, sedangkan (*X*) adalah fitur yang diperoleh dari proses ekstraksi pada lapisan sebelumnya. Adapun (*b*) merupakan nilai bias yang ditambahkan untuk membantu model menghasilkan prediksi yang lebih akurat.

HASIL DAN PEMBAHASAN

A. Karakteristik Dataset

Penelitian ini menggunakan dataset citra buah kelapa sawit yang terdiri atas tiga tingkat kematangan, yaitu mentah, setengah matang (mengkal), dan matang. Total dataset yang digunakan sebanyak 254 citra. Distribusi dataset dibuat seimbang antara kelas mentah dan matang, sedangkan kelas mengkal memiliki jumlah citra yang sedikit lebih rendah. Pembagian dataset dilakukan menggunakan metode stratified split sehingga proporsi setiap kelas tetap terjaga pada data pelatihan, validasi, dan pengujian.

Tabel 1 Distribusi Dataset

Kelas	Train	Validation	Test	Total
Mentah	64	13	14	91
Mengkal	50	11	11	72
Matang	63	14	14	91
Total	177	38	39	254

Berdasarkan Tabel 1, data pelatihan terdiri atas 177 citra (69,69%), data validasi sebanyak 38 citra (14,96%), dan data pengujian sebanyak 39 citra (15,35%). Pembagian tersebut bertujuan untuk menghasilkan model yang mampu belajar secara optimal sekaligus

mempertahankan kemampuan model dalam menghasilkan prediksi yang akurat pada data baru yang tidak digunakan selama proses pembelajaran.

B. Hasil Augmentasi Data

Penerapan augmentasi citra dilakukan untuk meningkatkan keberagaman data pelatihan sekaligus mengurangi potensi overfitting pada model. Augmentasi dilakukan melalui berbagai transformasi, baik yang bersifat geometris maupun perubahan karakteristik visual citra, sehingga diperoleh variasi data yang lebih representatif.

Tabel 2 Teknik Augmentasi Citra dan Tujuannya

No	Teknik Augmentasi	Tujuan
1	<i>Horizontal Flip</i>	Menambah variasi orientasi objek
2	<i>Vertical Flip</i>	Menambah variasi posisi objek
3	<i>Random Rotate 90°</i>	Mengatasi variasi sudut pengambilan gambar
4	<i>Color Jitter</i>	Menyesuaikan variasi pencahayaan dan warna
5	<i>Gaussian Blur</i>	Meningkatkan ketahanan terhadap citra kabur
6	<i>Random Shadow</i>	Mensimulasikan bayangan alami
7	<i>Grid Distortin</i>	Meningkatkan kemampuan generalisasi model

Penerapan augmentasi menghasilkan variasi data yang lebih beragam sehingga model dapat mempelajari karakteristik buah kelapa sawit dalam berbagai kondisi pencahayaan, orientasi, dan latar belakang. Hal ini penting karena citra di lapangan sering kali memiliki kondisi yang tidak seragam. Selanjutnya dilakukan distribusi data menjadi beberapa bagian. Distribusi kelas pada masing-masing subset ditunjukkan pada Tabel 3.

Tabel 3 Distribusi Kelas


Kelas	Train	Validation	Test
Mentah	64	13	14
Mengkal	50	11	11
Matang	63	14	14
	177	38	39

C. Hasil Pelatihan MobileNetv3-Large

Model MobileNetV3-Large dilatih menggunakan pendekatan *transfer learning* dengan memanfaatkan bobot pralatih dari ImageNet. Berdasarkan hasil pelatihan, model menunjukkan kemampuan yang cukup baik dalam mempelajari karakteristik visual tingkat

kematangan buah kelapa sawit. Nilai validasi terbaik diperoleh pada epoch ke-30 dengan validation accuracy sebesar 86,84%. Hasil tersebut menunjukkan bahwa MobileNetV3-Large mampu mengekstraksi fitur-fitur penting yang membedakan kelas mentah, mengkal, dan matang.

Berdasarkan Gambar 3, training loss dan validation loss menunjukkan tren penurunan selama proses pelatihan. *Training accuracy* meningkat hingga mencapai sekitar 95%, sedangkan *validation accuracy* terbaik mencapai 86,84%. Selain itu, nilai validation F1-




score mengalami peningkatan secara bertahap hingga mencapai sekitar 0,85 pada akhir pelatihan. Hasil tersebut menunjukkan bahwa MobileNetV3-Large mampu mempelajari karakteristik visual tingkat kematangan buah kelapa sawit dengan baik serta memiliki kemampuan generalisasi yang cukup stabil terhadap data validasi.

D. Hasil Pelatihan EfficientNet-B0

Model EfficientNet-B0 juga dilatih menggunakan pendekatan *transfer learning* dan *fine-tuning*. Hasil pelatihan menunjukkan performa yang lebih stabil dibandingkan MobileNetV3-Large.

Validation accuracy terbaik diperoleh pada epoch ke-28 dengan nilai 84,21%. Meskipun nilai validasi sedikit lebih rendah dibandingkan MobileNetV3-Large, performa pada data pengujian menunjukkan hasil yang lebih baik.



Gambar 4. Grafik Loss, Accuracy, dan Validation F1-Score EfficientNet-B0

Berdasarkan Gambar 4, nilai *training loss* dan *validation loss* menunjukkan tren penurunan selama proses pelatihan, yang mengindikasikan bahwa model mampu

mempelajari pola data dengan baik. Selain itu, *training accuracy* meningkat hingga sekitar 95%, sedangkan *validation accuracy* terbaik mencapai 84,21%. Nilai *validation F1-score* juga meningkat secara bertahap hingga mencapai lebih dari 0,80 pada akhir pelatihan. Hasil tersebut menunjukkan bahwa EfficientNet-B0 memiliki kemampuan yang baik dalam membedakan tingkat kematangan buah kelapa sawit dan menghasilkan performa pengujian terbaik dengan *accuracy* 92,31%, *precision* 92,86%, *recall* 92,86%, dan *F1-score* 92,20%.

E. Evaluasi Model

Evaluasi dilakukan menggunakan data uji sebanyak 39 citra dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.


Tabel 4 Hasil Evaluasi MobileNetV3-Large dan Hasil Evaluasi EfficientNet-B0

	Accuracy	Precision	Recall	F1-Score
MobileNetV3-Large	79,49%	82,94%	80,30%	79,58
EfficientNet-B0	92,31%	92,86%	92,86%	92,20

Hasil evaluasi menunjukkan bahwa EfficientNet-B0 memperoleh performa yang lebih tinggi dibandingkan MobileNetV3-Large pada seluruh metrik pengujian. Perbedaan paling signifikan terlihat pada nilai *accuracy*, yang meningkat dari 79,49% pada MobileNetV3-Large menjadi 92,31% pada EfficientNet-B0. Selain itu, EfficientNet-B0 juga menghasilkan nilai *precision*, *recall*, dan *F1-score* yang lebih tinggi, menunjukkan kemampuan klasifikasi yang lebih konsisten pada setiap kelas kematangan buah. Hasil tersebut mengindikasikan bahwa EfficientNet-B0 mampu mengekstraksi fitur visual buah kelapa sawit dengan lebih efektif dibandingkan MobileNetV3-Large. Kemampuan ini didukung oleh arsitektur EfficientNet yang menerapkan metode *compound scaling* sehingga dapat menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara optimal. Dengan demikian, EfficientNet-B0 dapat dianggap sebagai model yang lebih unggul dan lebih sesuai untuk diterapkan pada sistem klasifikasi kematangan buah kelapa sawit berbasis citra digital.

F. Confusion Matrix

Confusion matrix digunakan untuk mengevaluasi distribusi prediksi model terhadap masing-masing kelas kematangan buah.



a

Gambar 5 *Confusion Matrix EfficientNet-B0 (a) dan MobileNetV3-Large (b) Confusion*

Berdasarkan *confusion matrix* pada Gambar 5, kedua model mampu mengklasifikasikan tingkat kematangan buah kelapa sawit dengan baik. Namun, EfficientNet-B0 menunjukkan kinerja yang lebih unggul dengan jumlah prediksi benar yang lebih tinggi dan kesalahan klasifikasi yang lebih sedikit dibandingkan MobileNetV3-Large. Sebagian besar kesalahan pada kedua model terjadi pada kelas Mengkal, baik yang diprediksi sebagai Masak maupun Mentah. Hal ini menunjukkan bahwa kelas Mengkal memiliki karakteristik visual yang berada di antara kedua kelas tersebut sehingga lebih sulit dibedakan. Dengan demikian, EfficientNet-B0 dinilai lebih efektif dalam mengidentifikasi tingkat kematangan buah kelapa sawit pada dataset yang digunakan.

G. Analisis Perbandingan Model

Berdasarkan hasil evaluasi, EfficientNet-B0 menunjukkan performa terbaik dengan *accuracy* sebesar 92,31%, *precision* 92,86%, *recall* 92,86%, dan *F1-score* 92,20%. Sementara itu, MobileNetV3-Large memperoleh *accuracy* sebesar 79,49%, *precision* 82,94%, *recall* 80,30%, dan *F1-score* 79,58%. Performa yang lebih baik pada EfficientNet-B0 diduga disebabkan oleh mekanisme *compound scaling* yang digunakan untuk menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi input secara bersamaan. Pendekatan tersebut memungkinkan model mempelajari fitur visual yang lebih representatif

dibandingkan MobileNetV3-Large. Hasil ini sejalan dengan berbagai penelitian *Computer Vision* yang melaporkan bahwa EfficientNet mampu menghasilkan akurasi tinggi dengan jumlah parameter yang relatif efisien.

Diketahui bahwa *MobileNetV3-Large* memiliki keunggulan pada ukuran model yang lebih ringan dan kebutuhan komputasi yang lebih rendah. Namun, pada penelitian ini *EfficientNet-B0* terbukti lebih unggul dalam membedakan tingkat kematangan buah kelapa sawit. Jika dibandingkan dengan penelitian terdahulu mengenai klasifikasi kematangan buah kelapa sawit yang umumnya menghasilkan akurasi pada rentang 80–90%, hasil yang diperoleh *EfficientNet-B0* menunjukkan bahwa pendekatan Transfer Learning mampu memberikan peningkatan performa yang signifikan pada dataset lokal kelapa sawit.

H. Implikasi Penelitian

Hasil penelitian menunjukkan bahwa penerapan *computer vision* dan *transfer learning* memiliki potensi besar untuk mendukung digitalisasi sektor perkebunan kelapa sawit. Sistem klasifikasi otomatis mampu membantu proses identifikasi kematangan buah secara lebih objektif dan konsisten dibandingkan metode observasi visual yang bergantung pada pengalaman individu. Langkah meningkatkan efisiensi proses panen, teknologi ini juga berpotensi mengurangi kesalahan klasifikasi yang dapat berdampak pada penurunan kualitas minyak sawit. Dengan akurasi yang tinggi, model EfficientNet-B0 dapat menjadi dasar pengembangan sistem pendukung keputusan pada proses panen kelapa sawit sehingga produktivitas dan kualitas hasil perkebunan dapat ditingkatkan secara berkelanjutan.

KESIMPULAN

Penelitian ini berhasil menerapkan metode Transfer Learning untuk mengklasifikasikan tingkat kematangan buah kelapa sawit ke dalam tiga kategori, yaitu mentah, mengkal, dan matang, menggunakan arsitektur MobileNetV3-Large dan EfficientNet-B0. Proses penelitian meliputi tahapan preprocessing, augmentasi data, pelatihan model, serta evaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa kedua model mampu melakukan klasifikasi dengan baik, namun EfficientNet-B0 memberikan performa yang lebih unggul dibandingkan MobileNetV3-Large. EfficientNet-B0 memperoleh *accuracy* sebesar 92,31%, *precision* 92,86%, *recall* 92,86%, dan *F1-score* 92,20%, sedangkan MobileNetV3-Large memperoleh *accuracy* sebesar 79,49%, *precision* 82,94%, *recall* 80,30%, dan *F1-score* 79,58%. Hasil tersebut menunjukkan bahwa EfficientNet-B0 memiliki kemampuan yang lebih baik dalam

mengekstraksi fitur visual dan melakukan generalisasi terhadap data uji. Dengan demikian, penelitian ini memberikan kontribusi dalam pengembangan sistem klasifikasi kematangan buah kelapa sawit berbasis *computer vision* yang dapat mendukung proses identifikasi kematangan buah secara lebih objektif dan akurat. Penelitian selanjutnya dapat dilakukan dengan menambah jumlah dataset, memperluas variasi kondisi pengambilan citra, serta menguji arsitektur deep learning lainnya untuk meningkatkan performa klasifikasi.

UCAPAN TERIMA KASIH

Penelitian ini dapat diselesaikan berkat dukungan dari berbagai pihak. Penulis menyampaikan rasa syukur kepada Tuhan Yang Maha Esa atas segala rahmat dan kesempatan yang diberikan selama proses penelitian. Apresiasi diberikan kepada Program Studi Sistem Informasi Universitas Darwan Ali atas dukungan akademik serta fasilitas yang menunjang pelaksanaan penelitian. Penulis juga mengucapkan terima kasih kepada dosen pembimbing yang telah memberikan saran, arahan, dan masukan konstruktif selama proses penelitian hingga penyusunan artikel ilmiah ini.

DAFTAR PUSTAKA

- Ahmed Mansour, M. Y. M., Dambul, K. D., & Yeep, C. K. (2023). A REVIEW OF NON-DESTRUCTIVE RIPENESS CLASSIFICATION TECHNIQUES FOR OIL PALM FRESH FRUIT BUNCHES. In *Journal of Oil Palm Research* (Vol. 35, Number 4, pp. 543–554). Lembaga Minyak Sawit Malaysia. <https://doi.org/10.21894/jopr.2022.0063>
- Dianto, A. R., -, F. T. A., & -, H. M. (2025). ANALISIS EFEKTIFITAS ALGORITMA MOBILENETV3-LARGE DAN EFFICIENTNET-B0 UNTUK KLASIFIKASI CITRA PENYAKIT DAUN JERUK. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3). <https://doi.org/10.23960/jitet.v13i3.6956>
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., Adam, H., Ai, G., & Brain, G. (2019). *Searching for MobileNetV3*.
- Laurensia Trisely, T., & Wahyu Prabowo, D. (n.d.). Development of a Machine Learning Model for Automated Palm Fruit Ripeness Classification. In *Mentawa Baru Hulu Kec. Mentawa Baru Ketapang Kabupaten Kotawaringin Timur* (Number 10).
- Naufal Abiyyu, A., & Rahardi, M. (2026). Comparison of Transfer learning Models MobileNetV3-Large and EfficientNet-B0 for Rice Leaf Disease Classification. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 10, Number 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Nurahman, N., Minarni, M., Aziz, A., Winarti, L., Mashami, E., & Prabowo, D. W. (2025). Palm fruit ripeness classification using BorneoNet for improved accuracy in precision agriculture.

Edelweiss Applied Science and Technology, 9(11), 1389–1401.
<https://doi.org/10.55214/2576-8484.v9i11.11220>

- Pramudhita, D. A., Azzahra, F., Arfat, I. K., Magdalena, R., & Saidah, S. (2023). Strawberry Plant Diseases Classification Using CNN Based on MobileNetV3-Large and EfficientNet-B0 Architecture. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika*, 9(3), 522–534. <https://doi.org/10.26555/jiteki.v9i3.26341>
- 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>
- Suharjito, Elwirehardja, G. N., & Prayoga, J. S. (2021). Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches. *Computers and Electronics in Agriculture*, 188, 106359. <https://doi.org/10.1016/J.COMPAG.2021.106359>
- Suharjito, Junior, F. A., Koeswandy, Y. P., Debi, Nurhayati, P. W., Asrol, M., & Marimin. (2023). Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning. *Scientific Data*, 10. <https://doi.org/10.1038/s41597-023-01958-x>
- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*.
- Zulkarnain, J., Kusriani, & Hidayat, T. (2024). Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning. *JST (Jurnal Sains Dan Teknologi)*, 12(3). <https://doi.org/10.23887/jstundiksha.v12i3.59140>



© 2026 by authors. Content on this article is licensed under a Creative Commons Attribution 4.0 International license. (<http://creativecommons.org/licenses/by/4.0/>).