

# PENINGKATAN AKURASI KLASIFIKASI KEMATANGAN KELAPA SAWIT BERBASIS CITRA DENGAN ENSEMBLE DEEP LEARNING TEROPTIMASI DIMENSI RASIO

Ahmad Rifai Ikhsanudin\*<sup>1</sup>, Dian Ade Kurnia<sup>2</sup>, Yudhistira Arie Wijaya<sup>3</sup>, Dodi Solihudin<sup>4</sup>, Tati Suprapti<sup>5</sup>

Teknik Informatika<sup>1,4,5</sup>, Manajemen Informatika<sup>2</sup>, Sistem Informasi<sup>3</sup>,  
STMIK IKMI Cirebon<sup>1,2,3,4,5</sup>

ahmadrifaiikhsanudin7@gmail.com<sup>1</sup>, dianade2012@gmail.com<sup>2</sup>,

yudhistira010471@gmail.com<sup>3</sup>, dodisikmi@gmail.com<sup>4</sup>, tatisuprapti112004@gmail.com<sup>5</sup>

\* Corresponding Author : ahmadrifaiikhsanudin7@gmail.com

## Abstrak

Penentuan tingkat kematangan buah kelapa sawit secara manual sering menimbulkan subjektivitas dan menurunkan efisiensi. Penelitian ini mengembangkan metode klasifikasi berbasis citra menggunakan ensemble averaging pada tiga arsitektur MobileNetV2 dengan ukuran input berbeda (224×224, 224×300, dan 300×300) untuk mengurangi varians prediksi akibat variasi dimensi dan rasio aspek citra. Dataset yang digunakan berasal dari Kaggle berjumlah 1.380 citra, dengan pembagian 80% data latih dan 20% data validasi. Proses pengolahan mencakup rescaling, aspect-ratio-aware resizing, augmentasi, serta pelatihan menggunakan transfer learning dengan optimizer Adam dan early stopping. Hasil menunjukkan bahwa model berukuran 300×300 memberikan performa terbaik dengan akurasi 95,22% dan F1-score 0,9523. Ensemble averaging menghasilkan akurasi 94,71% dan F1-score 0,9475, yang meskipun sedikit lebih rendah dari model terbaik, memberikan stabilitas prediksi yang lebih baik dibanding model individual. Temuan ini menunjukkan bahwa resolusi input yang lebih tinggi meningkatkan kualitas ekstraksi fitur, sementara ensemble averaging tetap efektif dalam mereduksi varians dan meningkatkan ketahanan sistem klasifikasi di kondisi lapangan.

**Kata kunci:** Akurasi; ensemble\_averaging; klasifikasi\_citra; kematangan\_buah\_kelapa\_sawit; MobileNetV2.

## Abstract

*Manual assessment of oil palm fruit ripeness is often subjective and inefficient. This study proposes an image-based classification method using ensemble averaging on three MobileNetV2 models with different input resolutions (224×224, 224×300, and 300×300) to reduce prediction variance caused by variations in image dimensions and aspect ratios. The dataset consists of 1,380 images from Kaggle, split into 80% training and 20% validation. The preprocessing pipeline includes rescaling, aspect-ratio-aware resizing, and data augmentation, while model training employs transfer learning with the Adam optimizer and early stopping. Experimental results show that the 300×300 model achieves the highest performance with an accuracy of 95.22% and an F1-score of 0.9523. The ensemble model yields an accuracy of 94.71% and an F1-score of 0.9475, offering improved prediction stability despite slightly lower accuracy than the best single model. These findings emphasize that higher input resolution enhances feature extraction quality, and ensemble averaging effectively reduces variance, making it suitable for robust palm oil fruit ripeness detection in real-world applications.*

**Keywords:** Accuracy; ensemble\_averaging; image\_classification; oil\_palm\_fruit\_ripeness; MobileNetV2.

## 1. Pendahuluan

Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) telah mendorong pemanfaatan *computer vision* dalam berbagai sektor, termasuk pertanian. Pada industri kelapa sawit, penentuan tingkat kematangan Tandan Buah Segar (TBS) masih banyak dilakukan secara manual. Proses tersebut tidak hanya memakan waktu, tetapi juga rentan terhadap subjektivitas dan perbedaan persepsi antara pekerja lapangan. Mengingat tingkat kematangan TBS berpengaruh langsung terhadap rendemen minyak, metode klasifikasi berbasis citra digital menjadi solusi penting untuk meningkatkan kualitas panen dan efisiensi produksi.

Selain arsitektur model, ketersediaan dataset yang representatif turut menjadi faktor penting dalam meningkatkan performa model *deep learning*. Kontribusi [1] dalam menyediakan dataset terbuka beranotasi kematangan TBS memungkinkan para peneliti melakukan eksperimen dan evaluasi model secara lebih komprehensif. Dataset yang baik juga memfasilitasi penerapan pendekatan yang lebih kompleks, termasuk *ensemble learning*, untuk meningkatkan akurasi dan generalisasi model pada variasi kondisi lapangan.

### 1.1 Tujuan Penelitian

Penelitian ini berfokus pada analisis pengaruh variasi dimensi dan rasio aspek citra terhadap performa model *Convolutional Neural Network* (CNN) dalam melakukan klasifikasi tingkat kematangan buah kelapa sawit. Variasi ukuran dan perbandingan sisi citra dianggap berpotensi memengaruhi kualitas representasi fitur yang diekstraksi oleh model, sehingga penting untuk memahami sejauh mana perubahan tersebut dapat meningkatkan atau menurunkan akurasi klasifikasi. Dengan mengkaji berbagai konfigurasi dimensi dan rasio aspek, penelitian ini berupaya mengidentifikasi pengaturan citra yang paling optimal bagi kinerja model CNN.

Penelitian ini juga menerapkan dan mengevaluasi metode *ensemble learning* untuk menilai efektivitasnya dalam meningkatkan performa klasifikasi dibandingkan model CNN individual. Pendekatan *ensemble* memungkinkan penggabungan prediksi dari beberapa model sehingga menghasilkan keputusan yang lebih stabil dan akurat. Melalui proses pengujian dan evaluasi, penelitian ini berusaha mengungkap apakah metode *ensemble learning* mampu memberikan keunggulan yang signifikan dibandingkan kinerja model tunggal dalam mendeteksi tingkat kematangan buah kelapa sawit.

Selanjutnya, penelitian ini mengukur besarnya peningkatan performa yang dihasilkan oleh penerapan *ensemble learning* dibandingkan dengan model CNN individual yang sebelumnya telah dioptimasi menggunakan variasi dimensi dan rasio aspek citra. Pengukuran ini dilakukan untuk mengetahui kontribusi nyata dari metode *ensemble* terhadap peningkatan akurasi dan metrik evaluasi lainnya. Dengan membandingkan kedua pendekatan tersebut secara sistematis, penelitian ini memberikan gambaran yang lebih jelas mengenai nilai tambah yang diberikan oleh strategi *ensemble learning* dalam tugas klasifikasi citra.

### 1.2 Manfaat Penelitian

Secara teoretis, penelitian ini berkontribusi pada pengembangan *computer vision* dan *deep learning* melalui optimasi model CNN berbasis *ensemble learning* dengan mempertimbangkan variasi dimensi serta rasio aspek citra, sekaligus memperkaya literatur mengenai implementasi *multi-scale ensemble* pada klasifikasi citra pertanian. Temuan ini juga menjadi dasar bagi penelitian lanjutan terkait model yang lebih adaptif, teknik *aspect ratio-preserving*

*augmentation*, dan *integrasi multi-scale CNN ensemble* untuk meningkatkan generalisasi serta stabilitas sistem klasifikasi citra digital.

Secara praktis, penelitian ini memberikan manfaat langsung bagi industri kelapa sawit dan pertanian digital melalui pengembangan sistem klasifikasi kematangan buah yang efisien, akurat, mudah diimplementasikan, serta mampu meningkatkan konsistensi penilaian *real time*, mengurangi subjektivitas, dan mendukung otomatisasi proses panen maupun inspeksi mutu. Selain itu, model yang dikembangkan memiliki potensi untuk diterapkan pada berbagai komoditas pertanian lain dan berkontribusi pada percepatan transformasi digital pertanian Indonesia menuju sistem yang lebih cerdas, efisien, dan berkelanjutan.

## 2. Kajian Pustaka dan Pengembangan Hipotesis

### 2.1 Convolutional Neural Networks (CNN)

*Convolutional Neural Networks* (CNN) merupakan arsitektur *deep learning* yang efektif dalam mengekstraksi fitur spasial citra dan telah berkembang dari *LeNet* hingga *EfficientNet* dengan peningkatan signifikan pada efisiensi dan kualitas ekstraksi fitur. *MobileNetV2*, dengan *depthwise separable convolution*, *inverted residual blocks*, dan *Global Average Pooling*, menjadi arsitektur yang tepat untuk penelitian ini karena efisiensinya dan sensitivitasnya terhadap variasi dimensi citra dalam skema *ensemble multi-resolution*.

### 2.2 Ensemble Learning dalam Deep Learning

*Ensemble learning* merupakan teknik yang menggabungkan banyak model untuk meningkatkan stabilitas, mengurangi *varians*, dan memperkuat kemampuan generalisasi, termasuk melalui pendekatan seperti *soft voting*, *bagging*, dan *stacking*. Berbagai studi menunjukkan bahwa *ensemble* mampu menggabungkan representasi fitur yang beragam, meningkatkan akurasi, serta mengurangi *overfitting*, sehingga lebih unggul dibandingkan model tunggal.

### 2.3 Kajian Pustaka

Penelitian terdahulu terkait klasifikasi tingkat kematangan buah menggunakan pendekatan *deep learning* menunjukkan kemajuan signifikan dalam otomatisasi proses penilaian kualitas hasil pertanian. [2] mengevaluasi model YOLO dan SSD untuk deteksi kematangan buah stroberi dan alpukat, dengan hasil bahwa YOLOv6 memberikan kinerja terbaik dari segi akurasi dan kecepatan deteksi. Penelitian [3] mengintegrasikan CNN dan YOLOv5 untuk prediksi kematangan berbagai jenis buah, menunjukkan peningkatan ketahanan model terhadap variasi kondisi lingkungan.

[4] menerapkan *DenseNet201* dan *MobileNetV2* untuk estimasi kematangan multi-buah dan mencapai akurasi di atas 90%. [5] menggunakan *ResNet50* dalam klasifikasi tingkat kematangan buah kelapa sawit menjadi empat level kematangan, dengan hasil akurasi 97% dan menekankan pentingnya augmentasi data dalam meningkatkan performa model. Sementara itu, [6] menggunakan *AlexNet* untuk mendeteksi tingkat kematangan buah kelapa sawit dan memperoleh akurasi hingga 99,6%, melampaui model CNN konvensional. Keseluruhan studi tersebut menegaskan bahwa penggunaan arsitektur *deep learning* mampu meningkatkan akurasi, kecepatan, dan generalisasi sistem klasifikasi kematangan buah pada berbagai kondisi pencahayaan dan latar lingkungan.

Selain penelitian berbasis model tunggal, pendekatan *ensemble learning* semakin banyak diterapkan untuk meningkatkan generalisasi dan keandalan sistem pengenalan citra pertanian. [7] menunjukkan bahwa penerapan *ensemble* dan *transfer learning* mampu meningkatkan akurasi diagnosis penyakit tanaman dengan menggabungkan beragam data dan arsitektur

model. [8] menyoroti bahwa *ensemble architecture* efektif untuk mengatasi masalah ketidakseimbangan data dan variabilitas pada deteksi penyakit tanaman. [9] meninjau berbagai penelitian pemantauan tanaman dan menemukan bahwa sistem *ensemble CNN* memiliki peran penting dalam mengatasi masalah generalisasi rendah akibat kondisi lingkungan yang bervariasi.

[10] memperkenalkan kerangka kerja *hybrid ensemble* yang menggabungkan CNN, RNN, dan transformer-based models untuk meningkatkan manajemen pertumbuhan tanaman dan prediksi hasil panen. Sementara itu, [11] menerapkan *framework* deteksi berbasis *ensemble* dengan mengintegrasikan YOLO dan Faster R-CNN untuk meningkatkan presisi identifikasi buah dan hama pertanian. Berdasarkan keseluruhan hasil penelitian tersebut, pendekatan *ensemble learning* terbukti memberikan keunggulan dalam hal reliabilitas, stabilitas, serta kemampuan adaptasi model *deep learning* dalam konteks aplikasi pertanian modern.

### 3. Metode Penelitian

#### 3.1 Jenis Penelitian

penelitian ini menggunakan pendekatan eksperimen kuantitatif berbasis komputasi untuk mengevaluasi peningkatan akurasi klasifikasi tingkat pematangan buah kelapa sawit menggunakan metode *ensemble learning* dari beberapa model *Convolutional Neural Network* (CNN) dengan variasi dimensi dan rasio aspek citra. Pendekatan ini didasarkan pada prinsip replikasi dan validasi sistematis sebagaimana direkomendasikan oleh [12], [13], yang menekankan pentingnya pengujian berulang, *cross-validation*, serta evaluasi multi-metrik untuk menjamin keandalan hasil klasifikasi berbasis *deep learning*.

#### 3.1 Tahap 1 Persiapan Dataset

Tahap awal penelitian dilakukan dengan memuat dan memverifikasi dataset publik “*Ripeness of Oil Palm Fruit*” dari Kaggle, yang dipilih karena memenuhi kriteria penting seperti kondisi pencahayaan alami, tiga kelas kematangan standar industri, struktur folder yang rapi, serta resolusi citra yang seragam sehingga ideal untuk eksperimen *resizing* dan variasi rasio aspek. Setelah seluruh citra diperiksa integritasnya, divalidasi metadatanya, dan dipastikan bebas kerusakan file, dataset kemudian dibagi menggunakan *stratified split* menjadi 80% *training set* dan 20% *validation set* untuk memastikan keseimbangan kelas sebelum memasuki tahap pra-pemrosesan.

#### 3.2 Tahap 2 Pra-pemrosesan Data

Tahap *preprocessing* data dilakukan untuk memastikan seluruh citra memiliki ukuran, format, dan distribusi nilai piksel yang seragam melalui proses *normalisasi*, *augmentasi*, *resizing*, pembagian dataset, *one-hot encoding*, *batching*, serta penyesuaian data uji tanpa augmentasi. Serangkaian langkah ini bertujuan meningkatkan efisiensi pelatihan dan kemampuan generalisasi model CNN sehingga mampu mengenali tingkat kematangan buah kelapa sawit secara optimal.

#### 3.3 Tahap 3 Model Klasifikasi *Deep learning*

Tahap ini membangun arsitektur klasifikasi berbasis CNN dengan *transfer learning* menggunakan *MobileNetV2* sebagai *base model*, di mana tiga model individual (224×224, 224×300, dan 300×300) dikembangkan untuk menganalisis pengaruh variasi dimensi citra terhadap akurasi klasifikasi kematangan buah kelapa sawit. Seluruh model dikonstruksi melalui fungsi *create\_base\_model()* dengan membekukan bobot prelatih *MobileNetV2*, menambahkan lapisan *GAP*, *Dense*, dan *Softmax*, serta melakukan kompilasi menggunakan Adam dan

*categorical\_crossentropy*, sebelum kemudian ditinjau kembali melalui *model.summary()* untuk memastikan struktur arsitektur sesuai kebutuhan pelatihan.

### 3.4 Tahap 4 Pelatihan Model

Pada tahap ini dilakukan pelatihan tiga model CNN Model A (224×224), Model B (224×300), dan Model C (300×300) menggunakan data hasil augmentasi dengan pembagian 80% untuk pelatihan dan 20% untuk validasi, selama 25 epoch menggunakan optimizer Adam, *categorical\_crossentropy*, serta evaluasi akurasi, disertai *Early Stopping* dengan *patience* 5 untuk mencegah *overfitting* dan memulihkan bobot terbaik.

## 4. Hasil dan Pembahasan

### 4.1 Hasil

Bagian ini menyajikan hasil utama dari proses eksperimen model klasifikasi tingkat kematangan buah kelapa sawit, mulai dari kinerja model hingga analisis performa berdasarkan metrik evaluasi yang diperoleh.

Tabel 1. *Confusion Matrix*

<i>Model</i>	<i>Accuracy</i>	<i>F1-Score</i>	<i>Precision</i>
Model A	0.9355	0.9356	0.9361
Model B	0.8899	0.8917	0.9051
Model C	0.9522	0.9523	0.9526
<i>Ensemble (Voting/Averaging)</i>	0.9471	0.9475	0.9489

Berdasarkan Tabel 1. *Confusion Matrix*, terlihat bahwa setiap model memiliki tingkat akurasi dan presisi yang tinggi, namun dengan perbedaan kinerja yang cukup signifikan di antara masing-masing model. Model A menunjukkan performa yang sangat baik dengan *accuracy* sebesar 0.9355, *F1-Score* 0.9356, dan *precision* 0.9361, menandakan keseimbangan yang baik antara kemampuan model dalam mengenali kelas secara benar dan menjaga ketepatan prediksi.

Model B memiliki nilai performa yang sedikit lebih rendah dibandingkan model lainnya, dengan *accuracy* 0.8899, *F1-Score* 0.8917, dan *precision* 0.9051. Nilai ini menunjukkan bahwa meskipun model cukup akurat, masih terdapat beberapa kesalahan klasifikasi, terutama dalam menjaga konsistensi antara presisi dan recall, sehingga model ini relatif kurang stabil dibandingkan yang lain.

Sementara itu, Model C menampilkan performa terbaik di antara seluruh model individu dengan *accuracy* 0.9522, *F1-Score* 0.9523, dan *precision* 0.9526. Nilai yang tinggi dan seimbang ini menunjukkan bahwa Model C memiliki kemampuan klasifikasi yang sangat andal dan generalisasi yang baik terhadap data baru.

Adapun pendekatan *Ensemble (Voting/Averaging)* menunjukkan hasil yang kompetitif, dengan *accuracy* 0.9471, *F1-Score* 0.9475, dan *precision* 0.9489. Meskipun sedikit di bawah Model C, hasil ini membuktikan bahwa metode *ensemble* mampu menggabungkan keunggulan dari masing-masing model dasar untuk menghasilkan performa yang konsisten dan stabil. Secara keseluruhan, baik Model C maupun *Ensemble* dapat dianggap sebagai model yang paling optimal untuk tugas klasifikasi ini, dengan keseimbangan terbaik antara akurasi, presisi, dan *F1-score*.

Dengan demikian, metode *Voting/Averaging Ensemble* dapat dikatakan efektif dalam mengoptimalkan kinerja sistem klasifikasi, karena mampu menghasilkan performa yang stabil dan akurat pada dataset uji.

## 4.2 Pembahasan

Bagian ini membahas hasil eksperimen yang telah diperoleh dari proses pelatihan dan evaluasi model, termasuk analisis performa masing-masing arsitektur serta efektivitas pendekatan *ensemble learning*. Pembahasan disusun untuk memberikan pemahaman yang komprehensif mengenai faktor-faktor yang memengaruhi akurasi model serta implikasinya terhadap penerapan sistem klasifikasi tingkat kematangan buah kelapa sawit.

Tabel 2. *Classification Report*

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
BelumMasak	0.99	0.93	0.96	460
Masak	0.90	0.96	0.93	460
TerlaluMasak	0.96	0.95	0.96	460
<i>Accuracy</i>	—	—	<b>0.95</b>	1380
<i>Macro Avg</i>	0.95	0.95	0.95	1380
<i>Weighted Avg</i>	0.95	0.95	0.95	1380

Berdasarkan Tabel 2. *Classification Report* yang ditampilkan, Model *Ensemble (Final)* menunjukkan performa yang sangat baik dalam mengklasifikasikan tiga kelas tingkat kematangan, yaitu Belum Masak, Masak, dan Terlalu Masak. Nilai akurasi keseluruhan sebesar 0.95 (95%) menandakan bahwa model memiliki kemampuan prediksi yang tinggi dan stabil di seluruh kelas.

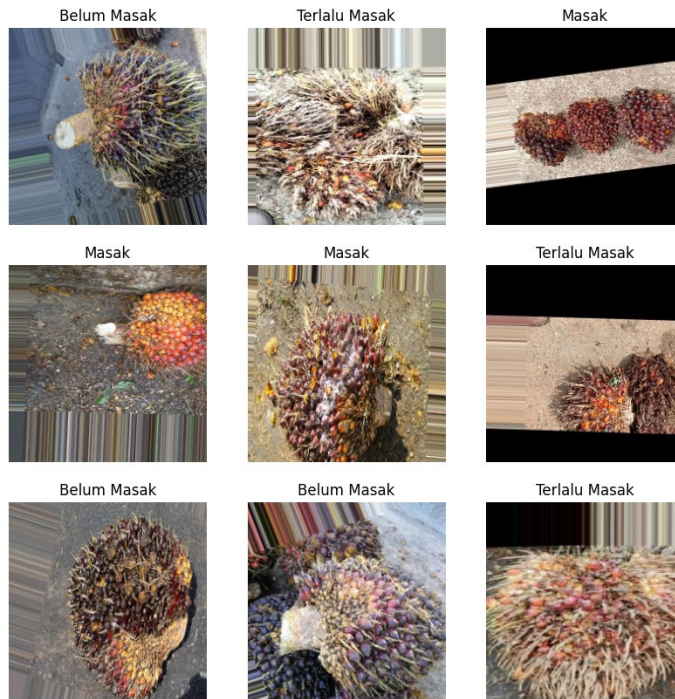
Pada kelas Belum Masak, model memperoleh nilai *precision* sebesar 0.99, *recall* sebesar 0.93, dan *f1-score* sebesar 0.96. Nilai *precision* yang sangat tinggi menunjukkan bahwa model jarang salah ketika memprediksi gambar sebagai Belum Masak, meskipun *recall* sedikit lebih rendah mengindikasikan masih ada sebagian kecil gambar Belum Masak yang tidak terdeteksi dengan benar.

Untuk kelas Masak, nilai *precision* sebesar 0.90, *recall* 0.96, dan *f1-score* 0.93 memperlihatkan bahwa model cukup baik dalam mengenali kelas ini, meskipun tingkat *precision* yang sedikit lebih rendah menunjukkan adanya beberapa kesalahan klasifikasi dari kelas lain ke Masak. Namun, *recall* yang tinggi menunjukkan bahwa sebagian besar gambar Masak berhasil diklasifikasikan dengan benar oleh model.

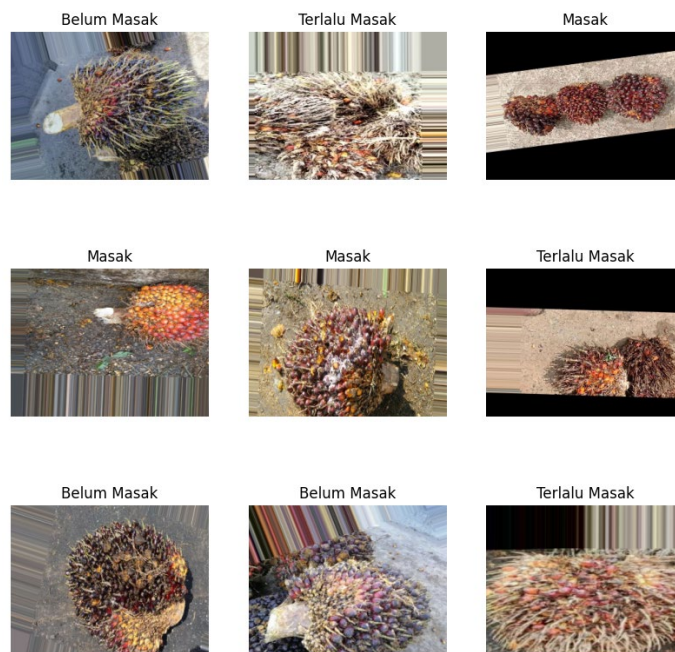
Pada kelas Terlalu Masak, model juga menunjukkan performa yang sangat baik dengan *precision* 0.96, *recall* 0.95, dan *f1-score* 0.96. Hal ini mengindikasikan keseimbangan yang baik antara ketepatan dan sensitivitas model dalam mengenali ciri visual khas buah yang terlalu matang.

Secara umum, nilai *macro average* dan *weighted average* yang sama-sama mencapai 0.95 menegaskan bahwa model memiliki performa yang konsisten di seluruh kelas tanpa dominasi dari satu kelas tertentu. Dengan demikian, Model *Ensemble (Final)* dapat disimpulkan memiliki kemampuan klasifikasi yang sangat andal dan seimbang, menjadikannya model yang optimal untuk mendeteksi tingkat kematangan berdasarkan citra dengan akurasi tinggi dan kesalahan minimal.

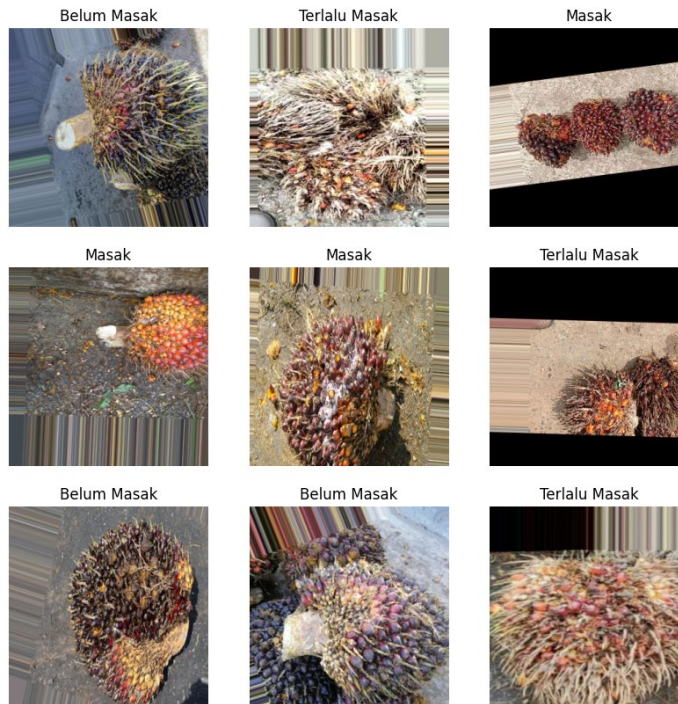
Untuk memberikan gambaran visual mengenai variasi citra dalam dataset, berikut ditampilkan contoh sampel dari masing-masing kelas kematangan buah kelapa sawit, yaitu Belum Masak, Masak, dan Terlalu Masak. Contoh-contoh ini menunjukkan perbedaan karakteristik visual antar kelas yang menjadi dasar bagi model dalam proses pembelajaran dan klasifikasi.



Gambar 1. Model A (224 × 224)

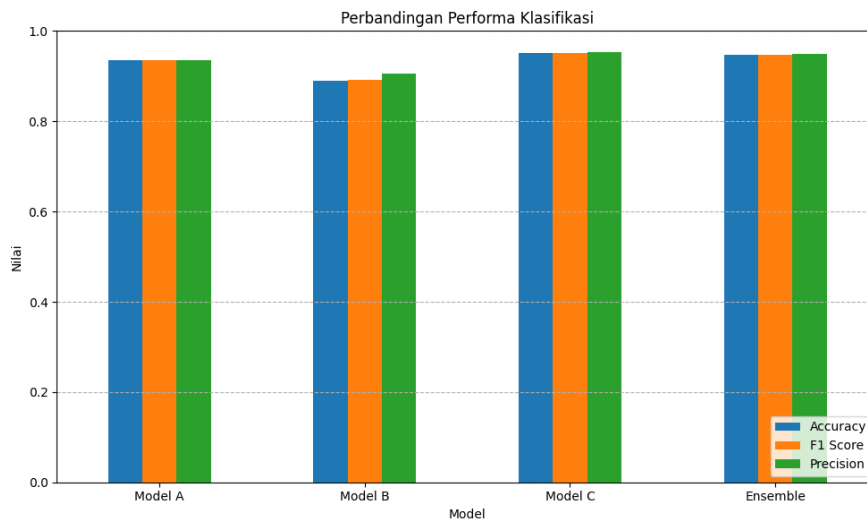


Gambar 2. Model B (224 × 300)



Gambar 3. Model C ( $300 \times 300$ )

Untuk memahami perbandingan kinerja dari setiap model yang diujikan, dilakukan visualisasi metrik utama berupa *Accuracy*, *F1-score*, dan *Precision* dari Model A, Model B, Model C, serta model *Ensemble*. Grafik berikut menyajikan perbedaan performa masing-masing model secara lebih jelas sehingga memudahkan analisis mengenai pengaruh variasi dimensi input dan penggunaan teknik *ensemble* terhadap hasil klasifikasi.



Gambar 4. Grafik Perbandingan

Gambar 4. tersebut menampilkan grafik perbandingan performa klasifikasi antara empat model, yaitu Model A, Model B, Model C, dan *Ensemble*, berdasarkan tiga metrik utama: *Accuracy*, *F1-Score*, dan *Precision*. Grafik ini bertujuan untuk memperlihatkan sejauh mana masing-masing model mampu mengklasifikasikan citra dengan tepat dan konsisten.

Berdasarkan grafik, terlihat bahwa Model C dan model *Ensemble* menunjukkan performa terbaik, dengan nilai *Accuracy*, *F1-score*, dan *Precision* yang semuanya berada di atas 0,95.

Hal ini menunjukkan bahwa kedua model tersebut memiliki kemampuan generalisasi yang sangat baik dalam mengenali pola data dan menghasilkan prediksi yang akurat serta konsisten antar kelas.

Sementara itu, Model A juga memperlihatkan performa yang tinggi dan stabil, dengan ketiga metriknya berada di kisaran 0,93–0,94, hanya sedikit di bawah Model C dan *Ensemble*. Adapun Model B memiliki nilai performa paling rendah di antara keempat model, dengan *Accuracy* dan *F1-score* sekitar 0,89–0,90, meskipun tetap menunjukkan hasil yang cukup baik secara keseluruhan.

Kinerja unggul dari model *Ensemble* memperkuat bukti bahwa pendekatan *ensemble learning* mampu meningkatkan akurasi dan stabilitas hasil klasifikasi dibandingkan model tunggal. Dengan menggabungkan prediksi dari beberapa model dasar, metode ini berhasil mengurangi kesalahan individual dari masing-masing model dan menghasilkan performa klasifikasi yang lebih optimal.

## 5. Kesimpulan dan Saran

### 5.1 Kesimpulan

Penelitian ini telah berhasil menunjukkan implementasi metode *deep learning* yang efektif dalam mengklasifikasikan tingkat kematangan buah kelapa sawit, di mana pengujian berbagai dimensi input citra dan penerapan teknik *ensemble* memberikan kontribusi penting terhadap pengembangan sistem klasifikasi berbasis citra digital untuk sektor pertanian. Hasil penelitian menunjukkan bahwa variasi dimensi input citra secara signifikan memengaruhi performa model CNN, dengan model berukuran 300×300 memberikan hasil paling optimal (*Accuracy* 0.9522, *F1-score* 0.9523, dan *Precision* 0.9526), sehingga menegaskan pentingnya resolusi dalam meningkatkan kemampuan ekstraksi fitur. Pendekatan *ensemble* berbasis *soft voting* juga terbukti mampu meningkatkan stabilitas prediksi meskipun akurasinya sedikit di bawah Model C yaitu 0.9471 namun tetap menunjukkan kinerja yang lebih konsisten dan *robust* terhadap variasi data. Model A (224×224) masih menunjukkan performa baik dengan *Accuracy* 0.9355, sedangkan Model B (224×300) justru mengalami penurunan *Accuracy* (0.8899), mengindikasikan bahwa perubahan rasio aspek yang tidak proporsional dapat mengurangi kualitas representasi fitur. Dataset *Ripeness of Oil Palm Fruit* dari Kaggle yang berjumlah 1.380 citra, dengan pembagian 80% pelatihan dan 20% validasi serta penggunaan augmentasi, *rescaling*, dan *transfer learning MobileNetV2*, berhasil mendukung proses pelatihan model secara optimal. Secara keseluruhan, penelitian ini membuktikan bahwa kombinasi pengaturan dimensi citra, strategi augmentasi, dan penggunaan *ensemble learning* dapat meningkatkan akurasi sekaligus stabilitas model dalam tugas klasifikasi tingkat kematangan buah kelapa sawit.

### 5.2 Saran

Untuk arah pengembangan berikutnya, penelitian dapat diperluas melalui integrasi data temporal seperti urutan video pendek atau penggabungan citra dengan metadata lingkungan sehingga model multimodal dapat memberikan prediksi yang lebih kontekstual. Penelitian ini juga masih terbatas pada satu dataset dengan kondisi pencahayaan alami tertentu, sehingga belum sepenuhnya mewakili variasi lingkungan yang lebih luas seperti perbedaan lokasi, musim, atau perangkat akuisisi citra. Oleh karena itu, penelitian selanjutnya disarankan memanfaatkan *weighted ensemble* atau *stacked ensemble*, mengimplementasikan augmentasi pencahayaan lanjutan, serta melakukan uji coba pada platform IoT atau drone untuk mendukung implementasi nyata di lapangan. Selain itu, evaluasi menggunakan *cross-plantation* dataset sangat dianjurkan untuk memastikan *robustness* dan generalisasi model terhadap kondisi kebun kelapa sawit yang beragam.

## Referensi

- [1] F. A. J. Suharjito, Y. P. Koeswandy, P. W. N. Debi, M. Asrol, and Marimin, 2023, “Annotated datasets of oil palm fruit bunch piles for ripeness grading using deep learning,” *Sci Data*, vol. 10, no. 58, doi: 10.1038/s41597-023-01958-x.
- [2] P. Kamat, S. Gite, H. Chandekar, L. Dlima, and B. Pradhan, 2025, “Multi-class fruit ripeness detection using YOLO and SSD object detection models,” *Heliyon*, doi: 10.1007/s42452-025-07617-7.
- [3] A. Mali, S. Patil, and S. A. Shinde, 2025, “Deep Learning-Based Fruit Detection and Ripeness Assessment,” *International Research Journal of Advanced Engineering and Management*, doi: 10.47392/irjaem.2025.0402.
- [4] A. G. Karegowda, D. U. Hemashree, and S. J. Sheela, 2024, “Fruit Classification and Ripeness Estimation using Deep Learning Models,” in *IEEE CSITSS*, doi: 10.1109/csitss64042.2024.10817041.
- [5] A. A. Hasibuan, A. A. Nst, A. Antoni, R. Handika, B. Yanto, and A. Zulkifli, 2024, “Advanced classification of oil palm fruit ripeness using ResNet50 and real-time image analysis for enhanced agricultural practices,” *Journal of ICT Applications and System*, vol. 3, no. 2, p. 395, doi: 10.56313/jictas.v3i2.395.
- [6] R. Kurniawan, S. Samsuryadi, F. S. Mohamad, H. O. L. Wijaya, and B. Santoso, 2025, “Classification of palm oil fruit ripeness based on AlexNet deep convolutional neural network,” *Sinergi*, vol. 25, no. 1, p. 19, doi: 10.22441/sinergi.2025.1.019.
- [7] Y. Yuan, L. Chen, H. Wu, and L. Li, 2021, “Advanced Agricultural Disease Image Recognition Technologies: A Review,” *Information Processing in Agriculture*, vol. 8, no. 1, pp. 1–13, doi: 10.1016/j.inpa.2021.01.003.
- [8] Y. Zarrouk, M. Bourhaleb, E. M. Bouyahrouzi, H. Hamdaoui, M. Rahmoune, and K. Hachami, 2025, “Deep Learning for Plant Disease Detection: Trends and Challenges,” in *IEEE ICCSC*. doi: 10.1109/iccsc66714.2025.11134855.
- [9] R. Zhang *et al.*, 2025, “A Bibliometric Review of Deep Learning in Crop Monitoring: Trends, Challenges, and Future Perspectives,” *Front Artif Intell*, vol. 8, p. 1636898, doi: 10.3389/frai.2025.1636898.
- [10] Z. Cao, S. Sun, and X. Bao, 2025, “A Review of Computer Vision and Deep Learning Applications in Crop Growth Management,” *Applied Sciences*, vol. 15, no. 15, p. 8438, doi: 10.3390/app15158438.
- [11] N. Wu, 2024, “Application and Evaluation of Deep Learning Based Image Recognition Techniques in Agriculture,” *Applied and Computational Engineering*, vol. 48, p. 1260, doi: 10.54254/2755-2721/48/20241260.
- [12] M. M. Hossain, M. R. Faruque, M. A. Rahman, and F. M. Shah, 2023, “An Empirical Evaluation of Deep Learning Ensemble Models for Image Classification,” *Sensors*, vol. 23, no. 14, p. 6538, doi: 10.3390/s23146538.
- [13] Y. Wang, H. Chen, S. Zhang, and X. Li, 2024, “Systematic Evaluation Protocols for Deep Learning Ensemble Models,” *IEEE Access*, vol. 12, pp. 65321–65335, doi: 10.1109/ACCESS.2024.3397845.