

Perancangan Aplikasi *Computer Vision* Berbasis *Convolutional Neural Network* Untuk Deteksi Kematangan Kelapa Sawit

Heri Setiawan¹, Kurniabudi², Sharipuddin³, Gunardi⁴

¹ Fakultas Ilmu Komputer, Magister Sistem Infomasi, Universitas Dinamika Bangsa, Jambi, Indonesia

Email: ¹heri75704@gmail.com, ²kurniabudi@unama.ac.id, ³sharifbuhaira@gmail.com, ⁴gun4rdi.sj@gmail.com

Email Penulis Korespondensi: heri75704@gmail.com

Artikel Info :

Artikel History :

Submitted : 15-09-2025

Accepted : 02-02-2025

Published : 30-04-2026

Kata Kunci:

Kelapa_Sawit,
Kematangan,
Computer_Vision,
Convolutional_Neural_Net
work, YOLOv5

Keywords:

Oil_Palm, Maturity,
Computer_Vision,
Convolutional_Neural_Net
work, YOLOv5,

Abstrak— Penentuan tingkat kematangan buah kelapa sawit secara manual masih menjadi tantangan signifikan bagi petani, menyebabkan inefisiensi dan penurunan kualitas hasil panen. Penelitian ini bertujuan untuk merancang dan mengimplementasikan aplikasi computer vision berbasis *Convolutional Neural Network* (CNN) guna mendeteksi kematangan buah sawit secara otomatis, objektif, dan efisien. Metode yang digunakan adalah pengembangan sistem berbasis web dengan model *Waterfall*, mengintegrasikan arsitektur YOLOv5s yang dimodifikasi dengan *Convolutional Block Attention Module* (CBAM), *C3 Transformer* (C3TR), dan *Bidirectional Feature Pyramid Network* (BiFPN). Dataset yang terdiri dari 4160 citra buah sawit diproses melalui *auto-orient*, *resize*, normalisasi warna, dan augmentasi data, kemudian dibagi menjadi 70% data latih, 20% validasi, dan 10% uji. Pelatihan model dilakukan di Google Colab menggunakan GPU Nvidia A100 selama 21.36 menit. Hasil evaluasi model menunjukkan kinerja yang sangat tinggi dengan *Precision* 0.9858, *Recall* 0.9910, *mAP@0.5* sebesar 0.9941, dan *mAP@0.5:0.95* sebesar 0.8544. *Confusion Matrix* dan kurva *Precision-Recall* mengindikasikan akurasi klasifikasi yang sangat baik dan kemampuan generalisasi model yang kuat. Implementasi sistem berbasis web memungkinkan petani mengunggah gambar atau video, serta menggunakan webcam untuk deteksi *real-time*. Aplikasi ini diharapkan dapat membantu petani dalam mengidentifikasi kematangan buah sawit secara lebih cepat dan objektif, meminimalkan kesalahan, dan meningkatkan kualitas serta efisiensi panen.

Abstract— Manual determination of oil palm fruit maturity remains a significant challenge for farmers, leading to inefficiencies and reduced harvest quality. This research aims to design and implement a computer vision application based on Convolutional Neural Network (CNN) to automatically, objectively, and efficiently detect oil palm fruit maturity. The methodology involves web-based system development using the Waterfall model, integrating a modified YOLOv5s architecture enhanced with a Convolutional Block Attention Module (CBAM), C3 Transformer (C3TR), and Bidirectional Feature Pyramid Network (BiFPN). A dataset of 4160 oil palm fruit images underwent auto-orient, resize, color normalization, and data augmentation, then split into 70% training, 20% validation, and 10% test sets. Model training was conducted on Google Colab using an Nvidia A100 GPU for 21.36 minutes. Evaluation results demonstrate very high performance with a Precision of 0.9858, Recall of 0.9910, mAP@0.5 of 0.9941, and mAP@0.5:0.95 of 0.8544. The Confusion Matrix and Precision-Recall curve indicate excellent classification accuracy and strong model generalization capabilities. The web-based system allows farmers to upload images or videos and use a webcam for real-time detection. This application is expected to assist farmers in identifying oil palm fruit maturity more quickly and objectively, minimizing errors, and improving harvest quality and efficiency.

1. PENDAHULUAN

Sektor pertanian merupakan salah satu pilar penting dalam mendukung ketahanan pangan dan pembangunan ekonomi nasional. Seiring dengan berkembangnya populasi dunia, kebutuhan terhadap hasil pertanian berkualitas semakin meningkat. Indonesia sebagai negara agraris memiliki berbagai komoditas unggulan, salah satunya adalah kelapa sawit yang menjadi penyumbang devisa terbesar di sektor perkebunan [1]. Produksi kelapa sawit tersebar luas di Sumatera dan Kalimantan, dengan kontribusi signifikan terhadap ekspor minyak nabati global. Namun demikian, produktivitas dan kualitas hasil panen kelapa sawit sangat bergantung pada ketepatan dalam menentukan tingkat kematangan Tandan Buah Segar (TBS) [2].

Penentuan tingkat kematangan TBS pada praktiknya masih banyak dilakukan secara manual dengan mengandalkan pengamatan visual petani atau pekerja lapangan. Cara tradisional ini bersifat subjektif, sangat dipengaruhi oleh pengalaman individu, serta berpotensi menimbulkan kesalahan panen [3]. Kesalahan dalam menentukan kematangan TBS dapat berdampak serius, baik berupa penurunan rendemen minyak, penurunan mutu produk akhir, maupun kerugian ekonomi bagi petani dan perusahaan perkebunan. Oleh karena itu, diperlukan suatu sistem yang mampu membantu proses identifikasi tingkat kematangan TBS secara cepat, objektif, dan konsisten.

Perkembangan teknologi *artificial intelligence* (AI) dan *computer vision* dalam dekade terakhir telah menghadirkan peluang besar untuk mengatasi tantangan di bidang pertanian [4], [5]. Dengan kemampuan mengekstraksi informasi visual dari citra maupun video, teknologi ini terbukti mampu meningkatkan efisiensi,

akurasi, serta kecepatan dalam berbagai proses pengolahan data pertanian [5]. Salah satu pendekatan populer adalah *Convolutional Neural Network* (CNN), yang dirancang khusus untuk klasifikasi citra dan telah diaplikasikan pada berbagai kasus, termasuk deteksi penyakit tanaman, pengenalan hama, hingga klasifikasi buah-buahan [6], [7]. Penelitian sebelumnya menunjukkan CNN dapat digunakan untuk mengklasifikasi tingkat kematangan buah tomat dan apel dengan hasil yang cukup memuaskan [8], [9].

Dalam konteks kelapa sawit, penelitian-penelitian terkini telah mencoba mengadaptasi CNN untuk mengidentifikasi kematangan buah berdasarkan ciri visual seperti warna dan tekstur [10], [11], [12]. Selain CNN, pendekatan berbasis deteksi objek real-time seperti YOLO (You Only Look Once) juga semakin banyak digunakan karena keunggulannya dalam kecepatan proses serta kemampuan mengidentifikasi objek langsung di lapangan [13], [14]. Model YOLOv4 dan YOLOv5 terbukti efektif dalam mendeteksi kematangan buah sawit secara cepat, bahkan dapat diintegrasikan dengan perangkat mobile maupun aplikasi berbasis web untuk mendukung operasional perkebunan [15], [16].

Meskipun hasil-hasil tersebut menjanjikan, beberapa kendala masih ditemui dalam implementasi sistem deteksi otomatis, seperti keterbatasan dataset representatif, variasi kondisi pencahayaan, latar belakang citra, hingga perbedaan varietas kelapa sawit [17]. Selain itu, petani kecil seringkali menghadapi keterbatasan sumber daya perangkat keras maupun pengetahuan teknis untuk menggunakan sistem berbasis AI. Oleh karena itu, penelitian ini diarahkan untuk mengembangkan sistem klasifikasi kematangan buah kelapa sawit berbasis CNN dengan arsitektur YOLOv5 yang dapat berjalan secara efisien, cepat, serta mudah diimplementasikan.

Dengan adanya sistem ini, diharapkan proses panen kelapa sawit menjadi lebih efektif dan objektif, mengurangi kesalahan manusia, serta meningkatkan rendemen minyak. Lebih jauh, penerapan teknologi ini berpotensi mendukung modernisasi sektor perkebunan kelapa sawit di Indonesia, meningkatkan daya saing komoditas di pasar global, serta membantu meningkatkan kesejahteraan petani rakyat yang menjadi pelaku utama dalam industri ini.


2. METODOLOGI PENELITIAN

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan *experimental research* dengan tujuan mengembangkan dan menguji sistem klasifikasi tingkat kematangan buah kelapa sawit berbasis *deep learning*. Tahapan penelitian meliputi: pengumpulan dataset, *preprocessing* citra, perancangan arsitektur CNN berbasis YOLOv5, pelatihan dan pengujian model, serta evaluasi performa menggunakan metrik standar.

2.2 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari kumpulan citra buah kelapa sawit dengan berbagai tingkat kematangan, yang dikumpulkan dari Roboflow Dataset oleh Binus [18]. Dataset ini telah dilabeli untuk memfasilitasi proses pelatihan model deep learning dalam deteksi objek terdapat 4160 total gambar. Kategori klasifikasi terdiri dari enam kelas (Janjang Kosong, Abnormal, Mentah, Kurang Masak, Masak, Terlalu Masak). Data kemudian dibagi menjadi set pelatihan, validasi, dan pengujian dengan rasio 70:20:10.



Gambar 1. Visualiasasi Dataset

2.3 Pra-pemrosesan

Sebelum data citra digunakan dalam proses pelatihan model, dilakukan beberapa tahap pra-pemrosesan untuk memastikan kualitas input dan meningkatkan kemampuan generalisasi model:

a. Auto-Orient

Setiap citra terlebih dahulu diperiksa orientasinya dan dilakukan koreksi otomatis menggunakan metadata EXIF. Tahap ini bertujuan agar citra yang diambil dengan berbagai perangkat kamera dapat memiliki orientasi yang seragam sehingga tidak menimbulkan distorsi arah pada proses pelatihan.

b. *Resize*

Seluruh citra diubah ukurannya menjadi 416×416 piksel menggunakan metode *stretch*. Pemilihan ukuran ini mengikuti standar input arsitektur YOLOv5 agar model dapat memproses data secara efisien tanpa kehilangan fitur penting dari objek.

c. Normalisasi Warna

Nilai piksel citra yang semula berada pada rentang 0–255 ditransformasikan ke rentang 0.0–1.0. Proses normalisasi ini berfungsi mempercepat konvergensi saat pelatihan jaringan saraf serta mengurangi bias akibat variasi intensitas cahaya pada citra lapangan.

d. Augmentasi Data

Untuk memperkaya keragaman data latih dan mencegah *overfitting*, diterapkan berbagai teknik augmentasi seperti rotasi, *flipping* horizontal/vertikal, penyesuaian kontras, *cropping* acak, serta *jittering* warna. Dengan augmentasi, model diharapkan lebih *robust* terhadap variasi kondisi pencahayaan, sudut pandang, dan tekstur objek yang ditemukan di lapangan.

2.4 Model dan Evaluasi

Arsitektur yang digunakan dalam penelitian ini adalah *You Only Look Once version 5* (YOLOv5) dengan modifikasi lapisan *Convolutional Neural Network* (CNN) untuk meningkatkan akurasi deteksi. YOLOv5 dipilih karena memiliki kemampuan deteksi objek secara *real-time* dengan kecepatan tinggi dan akurasi yang kompetitif.


Proses pelatihan menghasilkan model yang mampu mengenali tingkat kematangan buah sawit berdasarkan fitur visual. Hasil prediksi model kemudian dibandingkan dengan label ground truth untuk mengukur performa sistem. Evaluasi dilakukan menggunakan beberapa metrik, antara lain:

- Accuracy*, untuk mengukur tingkat ketepatan keseluruhan klasifikasi,
- Precision*, *Recall*, dan *F1-Score*, untuk mengevaluasi performa per kelas, serta
- mean Average Precision* (mAP) pada *threshold Intersection over Union* (IoU) 0.5 dan 0.5:0.95, yang digunakan sebagai indikator utama kinerja deteksi objek pada berbagai skala.

Dengan kombinasi model YOLOv5 dan metrik evaluasi ini, penelitian mampu menilai performa sistem baik dari aspek akurasi klasifikasi maupun kemampuan deteksi objek dalam skenario nyata.

2.5 Diagram Alur Penelitian


Untuk memberikan gambaran keseluruhan, metodologi penelitian ditunjukkan pada Gambar 2. Tahapan penelitian dimulai dari proses pra-pemrosesan data (auto-orientasi, resize citra, augmentasi, normalisasi, serta pembagian dataset), kemudian dilanjutkan dengan tahap backbone yang memanfaatkan kombinasi lapisan *Convolutional Block Attention Module* (CBAM) dan *C3 Transformer* (C3TR) untuk menghasilkan *multi-scale feature maps*. Selanjutnya, fitur tersebut diolah pada tahap *Neck* BiFPN (*Bidirectional Feature Pyramid Network*) untuk melakukan fusi *multi-level feature* sehingga memperkuat representasi objek kecil, sedang, maupun besar. Tahap berikutnya adalah *Head*, yang berfungsi mendeteksi objek (buah sawit) dalam tiga skala berbeda (*small*, *medium*, *large*). Hasil deteksi berupa *bounding box* kemudian diproses pada tahap *post-processing* melalui *Non-Maximum Suppression* (NMS), *thresholding*, dan penyesuaian skala *bounding box* untuk menghasilkan keluaran berupa klasifikasi tingkat kematangan buah sawit.



Gambar 2. Diagram alur metodologi penelitian (arsitektur YOLOv5 dengan CBAM dan BiFPN)

2.6 Metode Pengembangan Sistem

Metode waterfall adalah metode yang digunakan untuk mengembangkan sistem karena langkah kerjanya bertahap, sehingga kegiatan penelitian akan terstruktur dengan baik. Pendekatan alur hidup perangkat lunak yang dimulai dengan analisis, desain, pengkodean, dan pengujian diberikan oleh model air terjun atau waterfall. Gambar berikut menunjukkan model waterfall yang digunakan:



Gambar 3. Metode *Waterfall* [19]

Alasan pemilihan metode Waterfall karena pengerjaan dari suatu sistem dilakukan secara berurutan atau secara linear. Jadi jika langkah pertama belum selesai maka tidak akan bisa melanjutkan kelangkah kedua dan ketiga dan seterusnya. Secara otomatis tahapan yang ketiga akan bisa dilakukan jika tahap pertama dan kedua sudah diselesaikan.

Berdasarkan model Waterfall pada gambar 3 maka dapat dijelaskan setiap tahapan-tahapan dalam model tersebut sebagai berikut:

- Analisa Kebutuhan Perangkat Lunak**
Pada tahap ini dilakukan proses identifikasi kebutuhan perangkat lunak yang akan dikembangkan. Analisis mencakup kebutuhan sistem deteksi kematangan buah sawit, seperti spesifikasi dataset citra, preprocessing yang harus dilakukan (auto-orient, resize, normalisasi, augmentasi), serta arsitektur model yang digunakan (YOLOv5 dengan modifikasi CNN). Seluruh spesifikasi kebutuhan didokumentasikan sebagai acuan tahapan berikutnya.
- Desain Sistem**
Tahap desain mencakup perancangan alur pemrosesan data, arsitektur model, serta rancangan antarmuka aplikasi berbasis web. Proses ini mentranslasikan hasil analisis kebutuhan ke dalam representasi desain, misalnya melalui diagram alur metodologi, rancangan database untuk penyimpanan hasil deteksi, serta perancangan modul antarmuka pengguna yang sederhana agar mudah digunakan petani.
- Pembuatan Kode Program**
Setelah desain selesai, tahap ini menerjemahkan rancangan sistem ke dalam bentuk kode program. Implementasi dilakukan menggunakan bahasa Python dengan framework PyTorch untuk pengembangan

model CNN–YOLOv5, serta pemrograman berbasis web untuk integrasi sistem. Hasil pada tahap ini berupa sistem deteksi kematangan sawit yang siap diuji.

d. Pengujian Sistem

Tahap akhir dilakukan untuk memastikan perangkat lunak berfungsi sesuai kebutuhan. Pengujian dilakukan pada dataset uji dengan menggunakan metrik evaluasi (*Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *mAP*). Selain itu, pengujian *functional* juga dilakukan untuk memastikan aplikasi dapat berjalan sesuai rancangan. Hasil pengujian ini menjadi dasar evaluasi dan perbaikan terhadap sistem.

e. Pemeliharaan

Pada penelitian ini, pengembangan sistem hanya dilakukan sampai tahap pengujian. Tahap penerapan (*deployment*) dan pemeliharaan (*maintenance*), yang biasanya terdapat dalam model Waterfall, tidak dilakukan karena fokus penelitian adalah pada pengembangan dan evaluasi kinerja model deteksi kematangan buah sawit.

3. HASIL DAN PEMBAHASAN

3.1. Persiapan dan Konfigurasi Pelatihan

3.3.1. Lingkungan Pengujian

Pelatihan model dilakukan pada platform Google Colab dengan dukungan GPU Nvidia A100. Pemanfaatan GPU bertujuan mempercepat komputasi mengingat YOLOv5 berbasis arsitektur *Convolutional Neural Network* (CNN) dengan jumlah parameter besar. Lingkungan ini memungkinkan pelatihan berlangsung efisien tanpa membutuhkan perangkat keras lokal dengan spesifikasi tinggi. Proses pelatihan selesai dalam waktu sekitar 21,36 menit.

3.3.2. Parameter Pelatihan

Model yang digunakan adalah YOLOv5s yang dimodifikasi dengan modul CBAM, C3 *Transformer*, dan BiFPN. Bobot awal (*pre-trained weights*) diambil dari repositori Roboflow Universe. Parameter pelatihan ditetapkan sebagai berikut:

- Resolusi input: 416×416 piksel
- Batch size: 8
- Epoch: 100
- Optimizer: *Stochastic Gradient Descent* (SGD) dengan *learning rate* scheduler bawaan YOLOv5

Kombinasi parameter ini dipilih untuk menyeimbangkan akurasi tinggi dengan efisiensi waktu pelatihan, sehingga model tetap optimal untuk kebutuhan deteksi kematangan buah sawit di lapangan.

3.2. Hasil Penelitian

Model YOLOv5 yang telah dimodifikasi dengan penambahan modul CBAM, C3TR, dan BiFPN dilatih menggunakan dataset 4.160 citra TBS kelapa sawit yang dibagi menjadi training (2.908 citra, 10.137 instance), validation (835 citra, 3.006 instance), dan testing (417 citra, 1.410 instance).

Hasil evaluasi menunjukkan performa sangat baik pada ketiga subset data. Rangkuman nilai metrik utama ditunjukkan pada Tabel 1.

Tabel 1. Perbandingan Rata-Rata Hasil Evaluasi

Dataset	Images	Instances	Precision	Recall	F1-Score	mAP@0.5	mAP@0.5:0.95
Training	2908	10137	0.996	0.998	0.997	0.995	0.917
Testing	417	1410	0.991	0.996	0.994	0.994	0.887
Validation	835	3006	0.994	0.996	0.995	0.995	0.887

Visualisasi hasil deteksi pada citra uji ditunjukkan pada Gambar 4, dengan *bounding box* yang menampilkan kelas dan *confidence score* (0.8–1.0).




Gambar 4. Hasil deteksi YOLOv5 pada TBS kelapa sawit

3.2. Analisis Confusion Matrix

a. Training Set


Confusion matrix menunjukkan jumlah *True Positives (TP)* yang sangat tinggi, misalnya 564 (Janjang kosong) dan 1766 (Kurang masak), serta kesalahan klasifikasi (*off-diagonal*) yang sangat rendah. Jumlah *false positives (FP)* terhadap background juga minim, membuktikan ketepatan model. Nilai keseluruhan $P = 0.996$, $R = 0.998$, $F1 = 0.997$, $mAP@0.5 = 0.995$, $mAP@0.5:0.95 = 0.917$.



Gambar 5. Confusion Matrix Training

b. Testing Set


Confusion matrix mengonfirmasi performa stabil pada data baru dengan nilai $P = 0.991$, $R = 0.996$, $F1 = 0.994$, $mAP@0.5 = 0.994$, $mAP@0.5:0.95 = 0.887$. Kesalahan utama adalah *false negatives* kecil pada kelas “Kurang masak” (14 instance tidak terdeteksi).



Gambar 5. Confusion Matrix Testing

d. Validation Set

Nilai metrik serupa dengan testing, yaitu $P = 0.994$, $R = 0.996$, $F1 = 0.995$, $mAP@0.5 = 0.995$, $mAP@0.5:0.95 = 0.887$. *False positives* terhadap background sangat rendah, mengindikasikan generalisasi model yang baik.




Gambar 6. Confusion Matrix Validation

3.3. Analisis Kurva

3.3.1. Training dan Validation Loss

Kurva *training* dan *validation loss* (Gambar 7) menunjukkan tren penurunan yang stabil selama 100 epoch. Nilai akhir training box loss = 0.0145, validation box loss = 0.0128, dan class loss mendekati nol. Selisih kecil antara *training-validation loss* membuktikan tidak ada *overfitting* signifikan.




Gambar 7. Kurva Training dan Validation Loss

3.3.2. Metrik

Kurva *Precision*, *Recall*, dan *mAP* (Gambar 8) memperlihatkan peningkatan cepat pada 20–50 epoch pertama, kemudian konvergen mendekati nilai 1.0.

- Precision stabil di sekitar 0.99 - model jarang menghasilkan false positive.
- Recall konvergen di atas 0.99 - hampir semua objek berhasil terdeteksi.
- $mAP@0.5$ mendekati 1.0, sedangkan $mAP@0.5:0.95$ stabil di sekitar 0.85–0.89.



Gambar 8. Kurva Precision, Recall, dan mAP


3.4. Analisis Kebutuhan Sistem

Kebutuhan sistem dibagi menjadi fungsional dan non-fungsional. Kebutuhan fungsional meliputi deteksi kematangan TBS berbasis gambar, video, maupun webcam, klasifikasi ke enam kategori, serta antarmuka sederhana yang ramah pengguna. Sementara itu, kebutuhan non-fungsional menekankan akurasi, kinerja real-time (<5 detik/gambar), portabilitas berbasis web, serta keandalan sistem.

3.5. Desain dan Implementasi Sistem


Sistem dirancang dengan pendekatan Waterfall hingga tahap pengujian, meliputi:

- a. Use Case Diagram: mendefinisikan interaksi pengguna (petani) dengan aplikasi, seperti membuka aplikasi, memilih metode deteksi, hingga melihat hasil klasifikasi yang terdiri dari 1 aktor yaitu pengguna aplikasi tersebut.




Gambar 9. Use Case Diagram


Rancangan Antarmuka: tampilan dirancang sederhana dan interaktif dengan menu utama pada halaman beranda, form unggah gambar dan video, serta *live feed* webcam.



Gambar 10. Antarmuka Beranda



Gambar 11. Antarmuka Deteksi Pada Gambar



Gambar 12. Antarmuka Deteksi Pada Vidio




Gambar 13. Antarmuka Deteksi Pada Kamera

Implementasi Sistem: aplikasi berbasis web berhasil menampilkan hasil deteksi kematangan dengan bounding box dan label tingkat kematangan secara otomatis.



Gambar 14. Tampilan Beranda



Gambar 15. Tampilan Deteksi Pada Gambar



Gambar 16. Tampilan Deteksi Pada Vidio

3.6. Dampak Modul CBAM, C3TR, dan BiFPN

Penambahan modul-modul khusus pada arsitektur YOLOv5 terbukti memberikan dampak positif terhadap kinerja sistem.

- CBAM (*Convolutional Block Attention Module*) : meningkatkan fokus model pada fitur-fitur penting baik secara spasial maupun kanal. Dengan mekanisme ini, model dapat lebih akurat membedakan detail yang relevan, terutama dalam mendeteksi objek kecil atau yang memiliki perbedaan warna kontras rendah.
- C3TR (*C3 Transformer*) : memungkinkan pemodelan konteks global melalui mekanisme *self-attention*, sehingga model mampu menangkap hubungan jarak jauh antar fitur. Hal ini sangat membantu ketika objek memiliki kemiripan lokal namun perlu dibedakan berdasarkan konteks citra secara keseluruhan.
- BiFPN (*Bidirectional Feature Pyramid Network*) : memperkuat fusi fitur multiskala secara dua arah, yang membuat representasi objek pada berbagai ukuran menjadi lebih kaya dan stabil. Dengan demikian, model dapat mendeteksi baik objek besar maupun kecil dengan konsistensi yang lebih baik.

Kombinasi strategis ketiga modul ini tidak hanya meningkatkan akurasi deteksi, tetapi juga menjaga kemampuan generalisasi model. Walaupun terdapat kemungkinan sedikit memperlambat kecepatan inferensi, peningkatan kualitas prediksi yang diperoleh jauh lebih signifikan. Dengan kata lain, integrasi CBAM, C3TR, dan BiFPN memberikan keseimbangan antara akurasi tinggi dan ketahanan model dalam menghadapi variasi data di lapangan.

4. KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan aplikasi *computer vision* berbasis *Convolutional Neural Network* (CNN) dengan arsitektur YOLOv5s yang dimodifikasi menggunakan CBAM, C3 Transformer (C3TR), dan BiFPN untuk mendeteksi tingkat kematangan buah kelapa sawit. Hasil evaluasi menunjukkan kinerja yang sangat baik, dengan nilai rata-rata Precision 0.991, Recall 0.996, F1-Score 0.994, mAP@0.5 sebesar 0.994, dan mAP@0.5:0.95 sebesar 0.887 pada data uji.

Implementasi sistem berbasis web memungkinkan deteksi dilakukan melalui gambar, video, maupun kamera *real-time*, sehingga dapat membantu petani dalam menentukan tingkat kematangan tandan buah segar (TBS) secara cepat, objektif, dan konsisten. Penambahan modul CBAM, C3TR, dan BiFPN terbukti meningkatkan fokus fitur, memperkuat konteks global, serta mengoptimalkan fusi fitur multiskala sehingga akurasi deteksi semakin tinggi.

Meskipun demikian, penelitian ini masih memiliki keterbatasan, yaitu hanya sampai pada tahap pengujian tanpa mencakup implementasi pemeliharaan sistem. Selain itu, integrasi ke dalam aplikasi mobile native dan peningkatan kecepatan inferensi masih menjadi peluang pengembangan selanjutnya.

Secara keseluruhan, penelitian ini memberikan kontribusi nyata terhadap penerapan teknologi AI dan *computer vision* pada sektor perkebunan kelapa sawit di Indonesia, dengan potensi besar untuk meningkatkan efisiensi panen, kualitas hasil produksi, serta kesejahteraan petani.

REFERENCES

- [1] B. H. Simanjuntak, "Analisis produktivitas perkebunan kelapa sawit di Sumatera dan Kalimantan," *Jurnal Ekonomi dan Bisnis Perkebunan*, vol. 8, no. 1, pp. 30–45, 2020.

- [2] A. Hasibuan, F. Siregar, and M. Hidayat, "Pengaruh Tingkat Kematangan Tandan Buah Segar (TBS) terhadap Rendemen dan Mutu Minyak Kelapa Sawit," *Jurnal Ilmu dan Teknologi Perkebunan*, vol. 18, no. 3, pp. 112–128, 2022.
- [3] S. Hidayat and E. Nurhayati, "Studi kasus kesalahan panen pada perkebunan kelapa sawit rakyat," *Jurnal Agroekoteknologi*, vol. 14, no. 2, pp. 78–90, 2021.
- [4] P. R. Kumar, A. R. Singh, and M. R. K. Varma, "The role of artificial intelligence and computer vision in modern agriculture: A comprehensive review," *Journal of Agricultural Technology and Innovation*, vol. 5, no. 2, pp. 45–58, 2021.
- [5] L. P. Sari, D. P. Wardani, and S. M. Susanto, "Aplikasi computer vision dalam berbagai sektor industri: studi kasus di bidang kesehatan, manufaktur, dan transportasi," *Jurnal Teknologi Informasi*, vol. 15, no. 4, pp. 345–360, 2022.
- [6] S. Wahyuni and Y. Sulaeman, "Penerapan Deep Learning untuk Prediksi Harga Saham Menggunakan Metode Long Short-Term Memory (LSTM)," *Jurnal Sistem Informasi Bisnis*, vol. 12, no. 2, pp. 150–160, 2022.
- [7] B. T. Nugroho, "Aplikasi convolutional neural network (CNN) dalam klasifikasi objek di bidang pertanian: review dan prospek," *Jurnal Ilmu Komputer dan Informasi*, vol. 16, no. 1, pp. 1–15, 2021.
- [8] F. B. Setiawan, C. B. Adipradana, and L. H. Pratomo, "Fruit Ripeness Classification System Using Convolutional Neural Network (CNN) Method," *Protek: Jurnal Ilmiah Teknik Elektro*, vol. 10, no. 1, p., 2023, doi: 10.33387/protk.v10i1.5549.
- [9] B. Xiao, M. Nguyen, and W. Q. Yan, "Apple Ripeness Identification Using Deep Learning," 2021. doi: 10.1007/978-3-030-.
- [10] M. Rifqi and E. Suharjito, "Deteksi tingkat kematangan buah sawit berdasarkan komposisi warna menggunakan convolutional neural network," *Jurnal Sains dan Teknologi Komputer*, vol. 15, no. 2, pp. 170–185, 2021.
- [11] A. Syaifuddin, R. Wibowo, and D. Pratama, "Identifikasi Tingkat Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network (CNN) untuk Panen yang Efisien," *Jurnal Teknologi Pertanian*, vol. 24, no. 1, pp. 50–65, 2023.
- [12] S. Maysaroh, H. Purnomo, and A. Fitriani, "Identifikasi Kematangan Buah Sawit Berdasarkan Ekstraksi Warna RGB dan HSV Menggunakan Metode K-Means Clustering," *Jurnal Informatika Terapan*, vol. 15, no. 2, pp. 88–102, 2021.
- [13] D. Kurniawan, M. T. Handoko, and J. Prayoga, "Sistem klasifikasi kematangan buah sawit menggunakan YOLOv5 dan dataset citra," *Jurnal Teknologi dan Komputer Terapan*, vol. 13, no. 1, pp. 45–56, 2022.
- [14] A. Arsyad, R. Nugraha, and F. A. Ramadhan, "Pengembangan sistem deteksi kematangan buah sawit secara real-time menggunakan YOLOv4 dan video," *Jurnal Informatika*, vol. 17, no. 3, pp. 210–225, 2022.
- [15] E. Kurniawan, D. Saputra, and R. Ariyanto, "Performa convolutional neural network dalam klasifikasi tingkat kematangan buah apel dan tomat," *Jurnal Komputasi Pertanian*, vol. 7, no. 4, pp. 290–305, 2019.
- [16] A. Arsyad, R. Nugraha, and F. A. Ramadhan, "Sistem Deteksi Kematangan Buah Kelapa Sawit Secara Real-Time Menggunakan Arsitektur YOLOv4 untuk Aplikasi Mobile dan Web," *Jurnal Informatika*, vol. 17, no. 3, pp. 201–215, 2023.
- [17] M. R. Fadli, S. A. Ginting, and R. F. Pratama, "Analisis tantangan dan solusi dalam pengumpulan dataset untuk deep learning pada objek pertanian," *Jurnal Sistem Cerdas*, vol. 11, no. 2, pp. 140–155, 2020.
- [18] binus, "sawit Object Detection Model (v5)," 2022.
- [19] R. S. Pressman and B. R. Maxim, "Software Engineering." 2020.