

# Klasifikasi Tingkat Kematangan Buah Kelapa Sawit Menggunakan *EfficientNet-B7*

DOI: <http://dx.doi.org/10.35889/jutisi.v14i3.3399>

Creative Commons License 4.0 (CC BY – NC)

Valen Julyo Armando Davincylin<sup>1\*</sup>, Dedy Hermanto<sup>2</sup>

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

\*e-mail Corresponding Author: valenjulyoarmandodavincylin\_2226250045@mdp.ac.id

## Abstract

*Determining the ripeness level of oil palm fresh fruit bunches (FFB) is a crucial factor affecting oil yield and quality; however, field assessment is still largely performed manually and is prone to subjectivity and errors. This study aims to develop an image-based classification system for oil palm fruit ripeness using a Convolutional Neural Network (CNN) with the EfficientNet-B7 architecture. The proposed method applies transfer learning and fine-tuning on the public dataset "An Ordinal Dataset for Ripeness Level Classification in Oil Palm Fruit Quality Grading," which contains 4,728 images across five ripeness classes. The methodology includes image preprocessing, normalization, and data augmentation techniques such as rotation, flipping, and zooming. The model is trained using the Adam optimizer and evaluated using accuracy, precision, recall, and F1-score metrics. Experimental results show that the proposed model achieves an accuracy of 93.23% with stable performance across all classes. These findings indicate that EfficientNet-B7 is effective for oil palm fruit ripeness classification and has strong potential to be implemented as a decision-support system for more objective and consistent harvest timing.*

**Keywords:** *EfficientNet-B7; Convolutional Neural Network; Ripeness classification*

## Abstrak

Penentuan tingkat kematangan tandan buah segar (TBS) kelapa sawit merupakan faktor penting yang memengaruhi rendemen dan kualitas minyak sawit, namun proses penilaiannya di lapangan masih dilakukan secara manual sehingga rentan terhadap subjektivitas dan kesalahan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi tingkat kematangan buah kelapa sawit berbasis citra digital menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet-B7*. Metode yang digunakan meliputi *transfer learning* dan *fine-tuning* pada dataset publik "An Ordinal Dataset for Ripeness Level Classification in Oil Palm Fruit Quality Grading" yang terdiri dari 4.728 citra dalam lima kelas kematangan. Tahapan penelitian mencakup *preprocessing* citra, normalisasi, serta augmentasi data berupa rotasi, *flip*, dan *zoom*. Model dilatih menggunakan optimiser *Adam* dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa model mencapai *accuracy* sebesar 93,23% dengan performa klasifikasi yang stabil pada seluruh kelas. Berdasarkan hasil tersebut, *EfficientNet-B7* terbukti efektif untuk klasifikasi tingkat kematangan buah sawit dan berpotensi diterapkan sebagai sistem pendukung keputusan dalam penentuan waktu panen yang lebih objektif.

**Kata kunci:** *EfficientNet-B7; Convolutional Neural Network; Klasifikasi kematangan*

## 1. Pendahuluan

Perkebunan kelapa sawit di Indonesia semakin berkembang pesat dan saat ini sudah menjangkau lebih dari 20 provinsi di seluruh negeri dengan total produksi yang melebihi 50 juta ton setiap tahunnya. Tanaman sawit merupakan salah satu pilihan teratas untuk dijadikan sumber minyak nabati, dikarenakan tingginya nilai ekonomi serta permintaan pasar yang terus bertambah. Industri hilir pengolahan sawit memiliki peranan penting dalam menopang perekonomian nasional, terutama melalui penyerapan hasil panen petani, peningkatan

kesejahteraan pekebun mandiri, serta kontribusi besar terhadap perolehan devisa negara sekitar 14%. Besarnya potensi tanaman ini menjadikannya sebagai salah satu motor penggerak pembangunan ekonomi dan peningkatan taraf hidup masyarakat di daerah sentra produksi [1][2].

Produktivitas dan kualitas *Crude Palm Oil* (CPO) sangat tergantung pada tingkat kematangan tandan buah segar (TBS) pada saat melakukan panen. Buah yang dipanen terlalu muda menghasilkan rendemen minyak yang rendah, sedangkan panen yang terlalu matang dapat meningkatkan kadar *Free Fatty Acid* (FFA) sehingga menurunkan mutu minyak [3][4]. Namun, di lapangan, penetapan tingkat kematangan TBS masih dilakukan secara manual dengan mengandalkan pengamatan visual oleh pemanen, yang sangat tergantung pada pengalaman dan sudut pandang masing-masing individu. Metode ini bersifat subjektif dan berpotensi menimbulkan kesalahan, terutama pada perkebunan berskala besar, yang pada akhirnya berdampak pada kerugian rendemen dan efisiensi produksi [5].

Perkembangan kecerdasan buatan, khususnya *deep learning*, menawarkan solusi yang menjanjikan untuk mengatasi permasalahan tersebut melalui pemanfaatan citra digital dan visi komputer. *Convolutional Neural Network* (CNN) telah dibuktikan ampuh dalam menangkap fitur visual seperti warna dan tekstur secara otomatis dan tepat [6][7]. Salah satu arsitektur CNN modern yang memiliki performa unggul adalah *EfficientNet*, yang menerapkan metode *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi jaringan sehingga menciptakan akurasi tinggi dengan efisiensi komputasi yang optimal [8]. Varian *EfficientNet-B7*, sebagai model dengan kapasitas terbesar dalam keluarga *EfficientNet*, dinilai mampu menangkap perbedaan visual halus antar tingkat kematangan buah sawit, sehingga secara rasional dipilih sebagai solusi untuk meningkatkan akurasi klasifikasi TBS secara otomatis.

Dengan memperhatikan isu ini, studi ini bertujuan untuk mengembangkan suatu model klasifikasi tingkat kematangan buah kelapa sawit yang berbasis pada citra digital, dengan memanfaatkan algoritma *Convolutional Neural Network* (CNN) serta arsitektur *EfficientNet-B7*. Penelitian ini diharapkan memberikan kontribusi akademik dalam penerapan *deep learning* pada bidang agrikultur, khususnya klasifikasi kematangan buah sawit. Selain itu, temuan dari studi ini diharapkan mampu memberikan keuntungan nyata bagi sektor perkebunan, salah satunya sebagai pijakan untuk merancang sistem bantuan keputusan dalam menentukan waktu untuk panen, meningkatkan konsistensi penilaian mutu TBS, serta mendukung implementasi inspeksi kualitas secara otomatis dan real-time di lapangan maupun di pabrik pengolahan kelapa sawit.

## 2. Tinjauan Pustaka

Berbagai penelitian yang menggunakan *Convolutional Neural Network* (CNN) dalam untuk mengklasifikasikan gambar citra buah kelapa sawit menunjukkan kemajuan yang signifikan dalam beberapa tahun terakhir yang dapat di lihat pada Tabel 1 berikut.

**Tabel 1.** Perbandingan Penelitian Terkait.

Ref	CNN	EfficientNet	Dataset Citra Buah Tandan	Augmentasi Data
[9]	✓		✓	✓
[10]	✓		✓	✓
[11]	✓		✓	✓
[12]	✓		✓	✓
[13]			✓	
Ours	✓	✓	✓	✓

Penelitian oleh Aisah Rahmawati menjadi salah satu studi awal yang memanfaatkan CNN untuk membedakan buah sawit matang dan mentah pada variasi pencahayaan yang berbeda. Model CNN yang digunakan terbukti mampu mengenali ciri visual buah sawit dengan baik, ditunjukkan melalui akurasi sebesar 91,75% serta nilai *precision* dan *recall* yang tinggi [9]. Pendekatan CNN modern kemudian diperluas oleh Imam Afandy, melalui penerapan arsitektur *Xception* dengan strategi *transfer learning* dan augmentasi data berupa rotasi, *flipping*, serta perubahan pencahayaan. Model *Xception* yang dikembangkan mencapai akurasi 90% pada

dataset berisi 613 citra dua kelas, menunjukkan bahwa CNN modern bersifat adaptif terhadap variasi tekstur dan warna permukaan buah kelapa sawit [10].

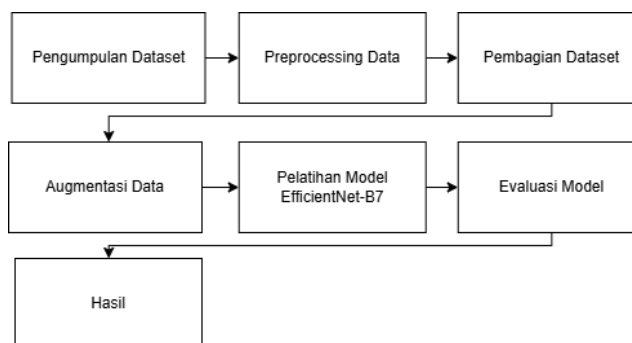
Selanjutnya, kinerja CNN arsitektur ringan juga ditunjukkan oleh Raihan Triyogi. yang menggunakan *MobileNet* untuk mengklasifikasikan tiga kategori kematangan, yaitu mentah, matang, dan busuk. Meskipun menggunakan dataset yang relatif kecil, *MobileNet* berhasil mencapai akurasi sempurna 100% pada data latih maupun uji, sehingga memperlihatkan potensi besar model CNN berarsitektur efisien untuk aplikasi di perangkat bergerak [11]. Di sisi lain, Mukhes Sri Muna. menciptakan sebuah model yang didasarkan pada *YOLOv8* untuk mengidentifikasi enam tahap kematangan buah kelapa sawit dan melaporkan presisi lebih dari 99%, yang menunjukkan kemajuan dalam kemampuan model pembelajaran mendalam untuk melakukan klasifikasi kematangan dengan detail dan secara langsung. Namun demikian, beberapa penelitian non-CNN modern masih menunjukkan keterbatasan [12].

Di sisi lain, sebelum pendekatan *deep learning* berkembang pesat, beberapa penelitian masih mengandalkan metode klasifikasi berbasis fitur warna. Ade Chandra Saputra dan Enny Dwi Oktaviyani menciptakan sebuah sistem untuk mengidentifikasi tingkat kematangan buah kelapa sawit dengan memanfaatkan analisis warna melalui algoritma *K-Nearest Neighbor* (K-NN). Sistem yang dibangun mampu mengklasifikasikan empat tingkat kematangan buah sawit dengan akurasi sebesar 86%, serta membantu proses pengambilan keputusan waktu panen. Namun, penelitian tersebut juga menunjukkan bahwa metode berbasis fitur warna memiliki keterbatasan dalam menangani variasi pencahayaan dan kompleksitas visual buah di lapangan [13].

Berdasarkan kajian terhadap penelitian-penelitian terdahulu, metode *deep learning* yang menggunakan *Convolutional Neural Network* (CNN) telah terbukti berhasil dalam mengklasifikasikan tahap kematangan buah kelapa sawit, dengan penerapan algoritma seperti CNN tradisional, *Xception*, *MobileNet*, dan *YOLO* yang umumnya masih terbatas pada dua hingga tiga kelas kematangan atau berfokus pada efisiensi dan deteksi *real-time*. Penelitian ini menghadirkan *state of the art* dengan mengusulkan penggunaan arsitektur *EfficientNet-B7*, yang menerapkan prinsip *compound scaling* untuk menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara optimal, guna mengklasifikasikan kematangan buah kelapa sawit ke dalam lima kelas (*Immature*, *Partially Ripe*, *Fully Ripe*, *Overripe*, dan *Decayed*). Dengan mengombinasikan strategi *transfer learning*, *fine-tuning* bertahap, serta augmentasi data, Model yang dirancang dapat mengidentifikasi perbedaan visual yang lebih halus di antara kategori dan meraih tingkat akurasi hingga 93,23% dengan metrik *precision*, *recall*, dan *F1-score* yang sangat baik. Kebaruan penelitian ini terletak pada penerapan *EfficientNet-B7* untuk klasifikasi kematangan buah kelapa sawit multi-kelas berbasis citra digital dengan evaluasi yang komprehensif, sehingga memberikan solusi yang lebih akurat, objektif, dan konsisten dibandingkan pendekatan sebelumnya.

### 3. Metodologi

Metodologi penelitian ini digunakan untuk mengimplementasikan proses pengembangan dan pengujian model klasifikasi tingkat kematangan buah kelapa sawit menggunakan arsitektur *EfficientNet-B7*. Seluruh tahapan penelitian mengikuti alur kerja yang ditunjukkan pada Gambar 1, dimulai dari pengumpulan data hingga dihasilkan model akhir yang telah melalui proses pelatihan dan evaluasi. Diagram alur tersebut menggambarkan hubungan antar proses secara sistematis sehingga memudahkan pemahaman terhadap urutan kegiatan penelitian.



**Gambar 1.** Tahapan-tahapan Dalam Penelitian.

Langkah awal dilakukan dengan mengumpulkan dataset citra buah kelapa sawit dari sumber publik Mendeley Data yang terdiri dari lima kategori tingkat kematangan. Dataset yang telah diperoleh kemudian melalui proses pra-pemrosesan citra, yaitu mengubah ukuran gambar menjadi 600×600 piksel, menormalkan nilai piksel agar seragam, dan memastikan seluruh citra berada dalam format masukan yang sesuai untuk proses pelatihan. Setelah itu dilakukan augmentasi data seperti *flipping*, *rotation*, *zoom*, dan penyesuaian pencahayaan untuk menambah variasi citra dan meningkatkan kemampuan generalisasi model. Dataset selanjutnya dibagi menjadi *training set*, *validation set*, dan *testing set* menggunakan metode *stratified split* agar distribusi tiap kelas tetap seimbang.

Tahapan berikutnya adalah pelatihan model *EfficientNet-B7* yang dilakukan melalui dua proses. Pertama, dilakukan *transfer learning* menggunakan bobot pralatih *ImageNet* untuk mengekstraksi fitur dasar dari citra sawit. Kedua, model dilanjutkan dengan proses *fine-tuning* dengan membuka sebagian lapisan akhir agar fitur yang dipelajari dapat menyesuaikan karakteristik citra buah sawit secara lebih spesifik. Proses pelatihan dioptimalkan menggunakan *optimizer Adam* dengan pengaturan *learning rate* bertingkat. Setelah model dianggap mencapai performa terbaik berdasarkan hasil validasi, tahap selanjutnya adalah pengujian menggunakan data *testing*. Evaluasi dilakukan untuk mengukur sejauh mana model mampu menggeneralisasi data baru melalui metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Model akhir kemudian digunakan sebagai hasil pengembangan untuk mengklasifikasikan citra sawit pada lima tingkat kematangan berbeda.

### 3.1. Pengumpulan Dataset

*Dataset* yang digunakan dalam penelitian ini adalah dataset publik yang dipublikasikan oleh Imam Mustafa Kamal di platform Mendeley Data. Dataset ini terdiri dari 4.728 citra resolusi tinggi buah kelapa sawit (*Elaeis guineensis*) yang dikategorikan ke dalam lima tingkat kematangan, yaitu *Immature*, *Partially Ripe*, *Fully Ripe*, *Overripe*, dan *Decayed*. serta dikembangkan oleh tim peneliti dari Institut Teknologi Sepuluh Nopember (ITS), Indonesia, yang di publish pada tanggal 27 November 2024 memiliki kredibilitas akademik terverifikasi [14].

Proses pelabelan atau anotasi dilakukan dengan pendekatan *class-level annotation*, di mana setiap citra diberi label tingkat kematangan berdasarkan penilaian ahli (*expert input*) tanpa penggunaan *bounding box* atau *segmentation mask*. Penentuan kategori didasarkan pada karakteristik visual buah seperti warna kulit, tekstur permukaan, dan kondisi fisik tandan. Seluruh citra disimpan dalam format *JPEG* dan telah terorganisasi dalam folder sesuai kelas kematangannya [14]. Karakteristik *dataset* dapat dilihat pada Tabel 2 berikut.

**Tabel 2.** Dataset Ordinal untuk Klasifikasi Tingkat Kematangan dalam Penilaian Kualitas Buah Kelapa Sawit.






Foto	Kelas	Jumlah Citra
	Immature	758
	Partially Ripe	1.405
	Fully Ripe	1.489

Foto	Kelas	Jumlah Citra
	<i>Overripe</i>	665
	<i>Decayed</i>	411

### 3.2. Preprocessing Data

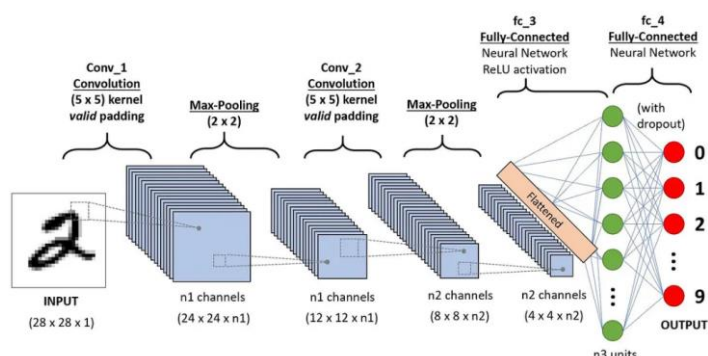
Pada penelitian ini tahap awal dilakukan proses *preprocessing* citra, yang mencakup perubahan ukuran gambar menjadi 600×600 piksel sesuai format masukan model *EfficientNet-B7* serta normalisasi nilai piksel agar berada pada rentang numerik seragam (−1 hingga 1). Langkah ini memastikan data citra memiliki distribusi yang stabil untuk diproses oleh jaringan saraf konvolusional.

### 3.3. Augmentasi Data

Pada tahap Augmentasi data guna memperluas variasi citra pada data latih melalui transformasi seperti *horizontal flip*, *rotation*, *zoom*, *brightness/contrast adjustment*, serta *translation*. Menurut penelitian C. Shorten dan T. M. Khoshgoftaar, teknik *augmentasi data* berperan penting dalam meningkatkan kemampuan generalisasi model *deep learning*, terutama saat jumlah data terbatas atau distribusi kelas tidak seimbang, sehingga model lebih tahan terhadap variasi kondisi pencahayaan dan posisi kamera di lapangan [15].

### 3.4. Algoritma Convolutional Neural Network

*Convolutional Neural Network* adalah arsitektur *deep learning* yang efektif untuk pengolahan citra. Jaringan ini menggunakan lapisan *convolution*, *pooling*, dan *fully connected* untuk otomatis mengekstrak fitur dari citra. *CNN* cocok untuk klasifikasi citra karena tidak memerlukan *feature engineering* manual yang berbasis domain spesifik [16]. Studi terdahulu menunjukkan bahwa *CNN* telah banyak digunakan untuk klasifikasi kematangan buah sawit [9]. Proses ini dapat dilihat Gambar 2.

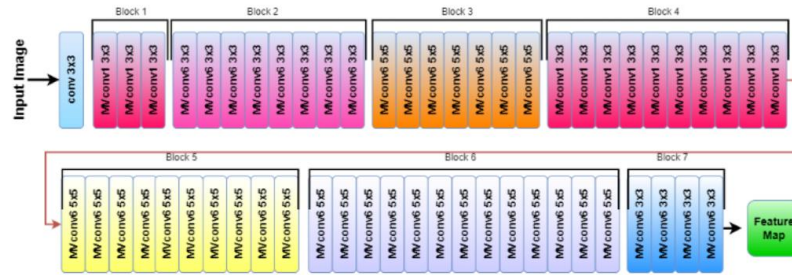


Gambar 2. Convolutional Neural Network (CNN)

### 3.5. Arsitektur EfficientNet-B7

*EfficientNet* merupakan keluarga model CNN yang dikembangkan oleh Tan & Le dengan prinsip utama *compound scaling* [8]. Pendekatan ini menyeimbangkan tiga aspek utama arsitektur jaringan, yaitu *depth*, *width*, dan *resolution*. Dengan menyeimbangkan ketiga parameter tersebut secara proporsional, *EfficientNet* dapat mencapai akurasi tinggi dengan efisiensi komputasi yang lebih baik dibandingkan model CNN konvensional. Varian *EfficientNet-B7* memiliki ukuran terbesar dalam keluarga *EfficientNet*, dengan resolusi

input 600×600 piksel dan jumlah parameter sekitar 66 juta, yang membuatnya mampu mengenali detail visual kompleks pada citra beresolusi tinggi. Model ini sangat sesuai untuk tugas klasifikasi tingkat kematangan buah sawit, yang memerlukan analisis fitur halus seperti perbedaan warna dan tekstur permukaan tandan. Contoh *EfficientNet-B7* dapat dilihat di Gambar 3.



Gambar 3. Arsitektur *EfficientNet-B7*

### 3.6. Evaluasi

Pada penelitian ini akan dilakukan pengujian terhadap model CNN dengan arsitektur *EfficientNet-B7* dengan menggunakan data uji. Hasil prediksi disusun dalam confusion matrix untuk setiap kelas buah kelapa sawit. Dari confusion matrix dihitung nilai precision, recall, accuracy, dan F1-Score sesuai dengan persamaan (1), (2), (3) dan (4).

Akurasi adalah ukuran untuk menguji seberapa efektif model dalam melakukan klasifikasi yang tepat. Nilai akurasi diperoleh dengan membandingkan jumlah prediksi yang benar terhadap total keseluruhan data. [11].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

Presisi merupakan ukuran evaluasi yang menunjukkan tingkat ketepatan model dalam meramalkan kejadian positif melalui berbagai metode prediksi. Angka presisi diperoleh dengan membandingkan data *True Positive* (TP) dengan total data yang memiliki nilai positif [11].

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

*Recall* adalah metrik evaluasi yang menilai seberapa efektif jenis gambar yang telah dikenali. Nilai *recall* diperoleh dengan membandingkan jumlah *True Positive* (TP) dengan keseluruhan data yang benar-benar positif [11].

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

*F1-Score* adalah mengukur kinerja dalam pencarian informasi yang menggabungkan hasil *recall* dan presisi. Nilai *F1-Score* diperoleh dengan mengambil rata-rata dari nilai presisi dan *recall* [11].

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$



## 4. Hasil dan Pembahasan

### 4.1. Proses Klasifikasi Tingkat Kematangan Buah

Proses mengklasifikasikan tingkat kematangan buah kelapa sawit dalam penelitian ini menggunakan model *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet-B7* yang telah melalui tahap pelatihan. Data masukan berupa citra tandan buah segar (TBS) yang dikelompokkan ke dalam lima kelas kematangan, yaitu *Immature*, *Partially Ripe*, *Fully Ripe*, *Overripe*, dan *Decayed*. Dataset disusun dalam struktur direktori terpisah untuk setiap kelas dan dibagi secara *stratified* ke dalam data latih 75%, data validasi 15%, dan data uji 10% guna menjaga keseimbangan distribusi kelas.

Sebelum dilakukan proses klasifikasi, seluruh citra buah kelapa sawit melalui tahap *preprocessing*. Tahapan ini meliputi perubahan ukuran citra menjadi 600×600 piksel, konversi citra ke format RGB, serta normalisasi nilai piksel -1 hingga 1 agar sesuai dengan masukan arsitektur *EfficientNet-B7*. Proses *preprocessing* bertujuan untuk menyeragamkan dimensi citra dan mengurangi pengaruh perbedaan resolusi serta kualitas citra terhadap kinerja model. Contoh hasil citra sebelum dan sesudah *preprocessing* ditampilkan pada Gambar 4, yang menunjukkan bahwa detail visual buah tetap terjaga meskipun ukuran citra telah diseragamkan.



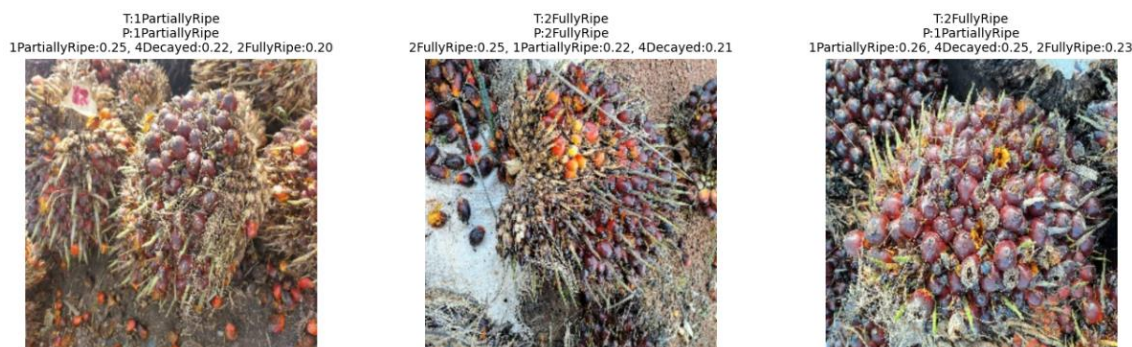
**Gambar 4.** Hasil *Preprocessing* Data.

Untuk meningkatkan variasi data dan menghindari terjadinya *overfitting*, dilakukan tahap data *augmentation* pada data latih. Teknik augmentasi yang digunakan mencakup *horizontal flipping*, rotasi acak, *zoom in/out*, translasi, penyesuaian kontras, serta perubahan tingkat kecerahan citra. Proses ini mensimulasikan kondisi lapangan yang beragam, seperti perbedaan sudut pengambilan gambar dan pencahayaan. Contoh hasil augmentasi citra buah kelapa sawit ditunjukkan pada Gambar 5, menyajikan perbandingan citra original dan citra hasil augmentasi dari setiap kelas tingkat kematangan buah kelapa sawit.



**Gambar 5.** Perbandingan Citra Original dan Citra Hasil Augmentasi

Setelah melalui tahap *preprocessing* dan augmentasi, citra diproses menggunakan fungsi *preprocess\_input* khusus *EfficientNet* agar sesuai dengan karakteristik bobot awal model hasil pra-pelatihan *ImageNet*. Selanjutnya, citra dimasukkan ke dalam jaringan *EfficientNet-B7* untuk dilakukan proses klasifikasi. Model mengekstraksi fitur visual dari tingkat rendah hingga tinggi melalui lapisan konvolusional, kemudian merangkum fitur tersebut menggunakan *global average pooling*. Pada tahap terakhir, lapisan *fully connected* menggunakan fungsi aktivasi *softmax* menghasilkan nilai probabilitas untuk setiap tingkatan kematangan, kemudian kelas yang memiliki probabilitas paling besar dipilih sebagai hasil prediksi.



**Gambar 6.** Hasil klasifikasi tingkat kematangan buah kelapa sawit


Hasil klasifikasi tingkat kematangan buah kelapa sawit ditunjukkan pada Gambar 6, yang menampilkan contoh citra uji beserta label aktual dan label prediksi model. Model mampu mengklasifikasikan citra dengan tingkat ketepatan yang tinggi, khususnya pada kelas *Immature* dan *Decayed* yang memiliki karakteristik visual yang kontras. Pada kelas *Partially Ripe*, *Fully Ripe*, dan *Overripe*, Meskipun ada kesamaan dalam penampilan antar kelas, model masih bisa memberikan hasil yang akurat dengan tingkat kepercayaan yang cukup. Secara keseluruhan, hasil ini menunjukkan bahwa *EfficientNet-B7* mampu mengklasifikasikan tingkat kematangan buah kelapa sawit secara otomatis dan konsisten, sehingga pantas dinilai kinerjanya.

#### 4.2. Hasil Evaluasi Model

Untuk mengevaluasi kinerja model *EfficientNet-B7* dalam klasifikasi tingkat kematangan buah kelapa sawit, digunakan skema pelatihan dua tahap yang terdiri dari transfer learning dan fine-tuning. Pendekatan ini dipilih karena model *EfficientNet-B7* memiliki jumlah parameter yang besar sehingga memerlukan strategi pelatihan bertahap agar stabil dan tidak mudah *overfitting*. Pada tahap transfer learning, seluruh lapisan backbone dibekukan dan hanya lapisan klasifikasi yang dilatih. Hasil pada Gambar 7 menunjukkan bahwa selama 25 *epoch* pertama, akurasi pelatihan dan validasi meningkat secara bertahap, sedangkan nilai *loss* terus berkurang, menunjukkan bahwa model berhasil memahami pola dasar dari gambar buah sawit.

Pada tahap kedua, *fine-tuning* dilakukan dengan membuka (*unfreezing*) sebagian lapisan akhir *EfficientNet-B7* agar model dapat menyesuaikan ekstraksi fitur tingkat atas sesuai karakteristik spesifik dataset sawit. Implementasi strategi ini menghasilkan lonjakan performa yang signifikan, ditunjukkan oleh peningkatan akurasi pelatihan hingga di atas 97% dan stabilisasi akurasi validasi pada kisaran 92–94%. Nilai *loss* validasi juga menunjukkan tren penurunan setelah proses *fine-tuning* dimulai, yang menegaskan bahwa model dapat mempelajari fitur tingkat tinggi tanpa mengalami degradasi performa (*validation degradation*). Secara keseluruhan, pola kurva pada Gambar 7 memperlihatkan bahwa skema dua tahap memberikan generalisasi yang lebih baik, meningkatkan konvergensi model, serta mencegah *overfitting* yang umum terjadi pada model berukuran besar.





**Gambar 7.** Grafik Perkembangan Akurasi dan Loss

Setelah proses pelatihan dua tahap (*transfer learning* dan *fine-tuning*) selesai dilakukan selama total 50 *epoch*, Model *EfficientNet-B7* kemudian diuji dengan data yang sudah disiapkan untuk mengetahui seberapa baik model bisa beradaptasi dengan gambar yang belum pernah dilihat sebelumnya. Evaluasi ini mencakup pengukuran *accuracy*, *precision*, *recall*, dan *F1-score* secara keseluruhan, serta analisis mendalam berdasarkan setiap kelas kematangan buah kelapa sawit. Hasil evaluasi ditampilkan pada Tabel 3 dan Tabel 4.

**Tabel 3.** Perfoma Utama Model *EfficientNet-B7* Berdasarkan Metrik *Accuracy*, *Precision*, *Recall* dan *F1-Score*.

Metrik	Nilai
<i>Accuracy</i>	0.9323
<i>Precision</i>	0.9455
<i>Recall</i>	0.9452
<i>F1-Score</i>	0.9438

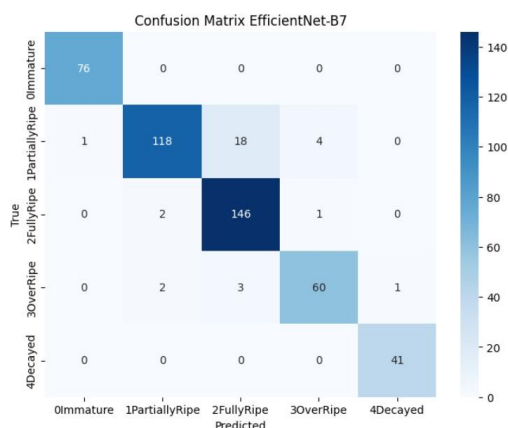
**Tabel 4.** *Classification Report* Berdasarkan Masing-Masing Kelas.

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Immature	0.99	1.00	0.99	76
Partially Ripe	0.97	0.84	0.90	141
Fully Ripe	0.87	0.98	0.92	149
Overripe	0.92	0.91	0.92	66
Decayed	0.98	1.00	0.99	41
Akurasi Total	-	-	0.93	473
Macro Average	0.95	0.95	0.94	473
Weighted Average	0.94	0.93	0.93	473

Berdasarkan hasil evaluasi tersebut, model *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet-B7* menunjukkan performa yang sangat baik dengan *accuracy* keseluruhan sebesar 93.23%, *precision* 94.55%, *recall* 94.52%, dan *F1-score* 94.38%. Nilai-nilai tersebut menunjukkan bahwa model bisa mengklasifikasikan dengan kesalahan yang sangat kecil, terutama mengingat tingkat kesulitan dari gambar buah sawit yang memiliki variasi cahaya, bentuk, sudut foto, serta kondisi lapangan yang tidak sama. Selain itu, nilai *macro average* dan *weighted average* yang konsisten berada pada kisaran 93–95% menunjukkan bahwa performa model relatif stabil pada seluruh kelas, tanpa bias dominan terhadap kelas tertentu.

Secara keseluruhan, hasil evaluasi tersebut menunjukkan bahwa model *EfficientNet-B7* tidak hanya mampu mempelajari pola visual yang kompleks, tetapi juga mampu membedakan dengan baik perbedaan tingkat kematangan buah kelapa sawit, bahkan pada kelas yang memiliki kesamaan fitur visual. Performa yang konsisten pada seluruh metrik membuktikan bahwa strategi pelatihan dua tahap dan penggunaan *augmentasi* data berhasil meningkatkan kemampuan generalisasi model terhadap kondisi lapangan yang beragam. Temuan ini memperkuat bahwa *EfficientNet-B7* merupakan arsitektur yang sangat efektif dan andal digunakan pada studi klasifikasi kematangan buah sawit berbasis citra.

Untuk memperoleh pemahaman yang lebih mendalam mengenai pola kesalahan prediksi dan kinerja model pada tiap kelas, dilakukan analisis melalui *confusion matrix*. Analisis ini penting karena meskipun metrik global menunjukkan performa yang tinggi, *confusion matrix* dapat mengungkap kelas mana yang paling sering mengalami kesalahan prediksi dan bagaimana distribusi ketepatan model pada masing-masing tingkat kematangan buah sawit. Dengan demikian, *confusion matrix* memberikan gambaran yang lebih jelas tentang kemampuan model dalam membedakan ciri-ciri visual setiap kelas, terutama pada kelas-kelas yang memiliki kesamaan dalam fitur, seperti *Partially Ripe*, *Fully Ripe*, dan *OverRipe*. Dapat dilihat pada Gambar 8, Distribusi prediksi untuk setiap kelas menampilkan bahwa model *EfficientNet-B7* mampu menerapkan klasifikasi dengan akurasi yang tinggi dengan tingkat kesalahan yang minimal.



**Gambar 8.** *Confusion Matrix Model EfficientNet-B7 Pada Data Uji.*

Setelah memperhatikan Gambar 8, terlihat bahwa model *EfficientNet-B7* berhasil mengklasifikasikan sebagian besar citra secara benar dengan jumlah kesalahan yang sangat kecil pada setiap kelas. Kelas *Immature* dan *Decayed* menunjukkan performa yang sempurna, ditandai dengan nilai diagonal sebesar 100% dan tidak adanya prediksi silang ke kelas lain. Hal ini mengindikasikan bahwa karakteristik visual pada dua kelas tersebut mudah dikenali oleh model karena memiliki pola warna, tekstur, dan bentuk yang sangat khas.

Pada kelas *Partially Ripe*, sebagian kecil citra terklasifikasi sebagai *Fully Ripe* atau *OverRipe*, yang wajar mengingat transisi visual antar kelas ini relatif berdekatan. Pola kesalahan ini menunjukkan bahwa fitur visual antara tingkat kematangan tengah memiliki kemiripan yang tinggi, terutama pada warna permukaan buah dan kepadatan minyak. Meski demikian, mayoritas prediksi tetap berada pada kelas yang benar, yang membuktikan bahwa model mampu menangkap perubahan visual secara bertahap di antara tingkatan kematangan buah sawit.

Untuk kelas *Fully Ripe* dan *OverRipe*, model juga berhasil melakukan klasifikasi dengan akurasi tinggi, ditandai dengan dominasi nilai diagonal pada *confusion matrix*. Hanya sebagian kecil citra yang tertukar antar kedua kelas tersebut. Kesalahan kecil ini dapat terjadi akibat variasi pencahayaan atau sudut pengambilan gambar yang mempengaruhi warna visual buah sawit sehingga menyerupai kelas sebelahnya. Secara keseluruhan, pola pada *confusion matrix* ini menunjukkan bahwa model tidak hanya memiliki performa global yang tinggi, tetapi juga konsisten dan stabil pada setiap kelas, sehingga layak digunakan pada implementasi nyata dalam penentuan tingkat kematangan buah sawit.

### 4.3. Pembahasan

Penelitian ini menganalisis performa model *EfficientNet-B7* dalam mengklasifikasikan tingkat kematangan buah kelapa sawit melalui dua tahap pelatihan, yaitu *transfer learning* dan *fine-tuning*. Pendekatan pelatihan bertahap ini dipilih untuk mengatasi kompleksitas arsitektur *EfficientNet-B7* yang memiliki jumlah parameter besar, sehingga membutuhkan strategi pembelajaran yang stabil agar mampu melakukan generalisasi dengan baik pada data citra lapangan yang beragam.

Hasil penelitian ini memperkuat temuan penelitian terdahulu yang menyatakan bahwa *deep learning* berbasis *Convolutional Neural Network* (CNN) efektif dalam klasifikasi kematangan buah kelapa sawit. Penelitian oleh Rahmawati. menunjukkan bahwa CNN mampu mencapai akurasi di atas 90% dalam membedakan buah sawit matang dan mentah pada variasi pencahayaan [9]. Temuan tersebut diperluas dalam penelitian ini dengan menunjukkan bahwa algoritma *Convolutional Neural Network* (CNN) yang lebih kompleks, yaitu *EfficientNet-B7*, tetap mampu mempertahankan performa tinggi meskipun jumlah kelas kematangan ditingkatkan menjadi lima kelas. Hal ini menunjukkan bahwa *EfficientNet-B7* memiliki kemampuan representasi fitur visual yang lebih kuat dibandingkan CNN konvensional.

Selain itu, hasil penelitian ini juga memperkuat temuan Afandy. yang menerapkan arsitektur *Xception* dengan pendekatan *transfer learning* dan augmentasi data [10]. Sejalan dengan penelitian tersebut, penelitian ini membuktikan bahwa kombinasi *transfer learning* dan *fine-tuning* mampu meningkatkan stabilitas pelatihan dan performa model. Namun, berbeda dari penelitian Afandy. yang hanya mengklasifikasikan dua kelas kematangan, penelitian ini memperluas ruang lingkup klasifikasi ke dalam lima kelas dengan tetap mempertahankan akurasi yang tinggi, sehingga memberikan kontribusi tambahan pada literatur terkait klasifikasi kematangan buah sawit.

Dari sisi efisiensi model, penelitian Triyogi. menunjukkan bahwa *MobileNet* mampu mencapai akurasi tinggi pada klasifikasi tiga kelas kematangan, terutama untuk aplikasi perangkat bergerak [11]. Temuan tersebut tidak bertentangan dengan hasil penelitian ini, tetapi menunjukkan adanya perbedaan fokus. Sementara *MobileNet* menekankan efisiensi komputasi, penelitian ini menitikberatkan pada ketelitian klasifikasi multi-kelas dengan perbedaan visual yang lebih halus. Dengan demikian, penelitian ini melengkapi penelitian sebelumnya dengan menawarkan solusi yang lebih akurat untuk kebutuhan penilaian mutu yang detail di tingkat industri.

Penelitian ini juga memberikan klarifikasi terhadap keterbatasan metode klasik berbasis fitur warna, seperti yang dilaporkan oleh Saputra dan Oktaviyani serta Parinduri. yang menunjukkan bahwa algoritma K-NN dan SVM kurang stabil dalam menghadapi variasi pencahayaan dan kompleksitas visual buah sawit [13][17]. Hasil penelitian ini menegaskan bahwa pendekatan *deep learning* modern, khususnya *EfficientNet-B7*, lebih unggul dalam mengekstraksi fitur warna dan tekstur secara otomatis tanpa ketergantungan pada perancangan fitur manual.

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan berasal dari satu sumber publik dengan kondisi pengambilan citra tertentu, sehingga variasi kondisi ekstrem di lapangan, seperti perbedaan jenis kamera, cuaca, dan latar belakang yang lebih beragam, belum sepenuhnya terakomodasi. Selain itu, penelitian ini masih berfokus pada klasifikasi berbasis citra statis, sehingga belum mengakomodasi kebutuhan implementasi *real-time* di lingkungan perkebunan atau pabrik pengolahan. Dari sisi komputasi, arsitektur *EfficientNet-B7* memiliki kompleksitas yang relatif tinggi, sehingga berpotensi menjadi kendala apabila diterapkan pada perangkat dengan sumber daya terbatas.

Berdasarkan keterbatasan tersebut, disarankan untuk melakukan penelitian berikutnya dengan menggunakan dataset yang lebih besar dan lebih beragam, termasuk data yang diperoleh langsung dari berbagai lokasi perkebunan dengan kondisi lingkungan yang berbeda. Selain itu, pengembangan ke arah implementasi *real-time* menggunakan perangkat kamera lapangan perlu dikaji lebih lanjut. Penelitian mendatang juga dapat mengeksplorasi perbandingan dengan arsitektur lain seperti *EfficientNet-V2*, *Vision Transformer*, atau pendekatan *ensemble* untuk memperoleh keseimbangan antara akurasi dan efisiensi komputasi.

Secara keseluruhan, kontribusi utama penelitian ini terletak pada penguatan bukti empiris bahwa algoritma *Convolutional Neural Network* (CNN) modern dengan kapasitas tinggi mampu meningkatkan akurasi dan konsistensi klasifikasi kematangan buah kelapa sawit multi-kelas. Dengan mengintegrasikan temuan penelitian ini ke dalam kumpulan penelitian terdahulu, dapat disimpulkan bahwa *EfficientNet-B7* tidak hanya sejalan dengan perkembangan riset sebelumnya, tetapi juga memperluas batasan penelitian dengan menawarkan pendekatan yang lebih komprehensif dan aplikatif untuk sistem inspeksi otomatis dan pendukung keputusan panen di industri kelapa sawit.

## 5. Simpulan

Penelitian ini menunjukkan bahwa *EfficientNet-B7* mampu mengklasifikasikan tingkat kematangan buah kelapa sawit dengan sangat baik melalui pendekatan *transfer learning* dan *fine-tuning*. Model berhasil menghasilkan akurasi 93,23% dengan *precision*, *recall*, dan *F1-score* di atas 94%, menandakan kemampuan generalisasi yang kuat terhadap variasi warna, tekstur, dan kondisi pencahayaan pada citra buah sawit. Analisis *confusion matrix* memperlihatkan bahwa sebagian besar kelas dapat diprediksi dengan akurat, meskipun kelas yang memiliki kemiripan visual masih menunjukkan kesalahan minor. Hasil ini menegaskan bahwa *EfficientNet-B7* merupakan arsitektur yang efektif untuk tugas klasifikasi agrikultur berbasis citra dan memiliki potensi besar untuk mendukung proses panen serta pengolahan kelapa sawit secara lebih objektif dan efisien.

## Daftar Referensi

- [1] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [2] GAPKI, "Kinerja Industri Minyak Sawit Tahun 2023 & Prospek Tahun 2024." [Online]. Available: <https://gapki.id/news/2024/02/27/kinerja-industri-minyak-sawit-tahun-2023-prospek-tahun-2024/>
- [3] F. Murgianto, Edyson, A. Ardiyanto, S. K. Putra, and L. Prabowo, "Potensi Kandungan Minyak Kelapa Sawit dengan Berbagai Tingkat Berondolan Lepas di Piringan ( Potential Content of Palm Oil at Various Levels of Loose Fruit in Oil Palm Circle )," *Agro Ind. Perkeb.*, vol. 9, no. 2, pp. 91–98, 2021.
- [4] D. Bayu, Priyambada, and G. Supriyanto, "Analisis Rendemen Minyak Kelapa Sawit (CPO) berdasarkan Tingkat Kematangan Buah di PT . Bumitama Gunajaya Agro," *J. Agroforetech*, vol. 1, no. 03, pp. 2051–2060, 2023.
- [5] W. E. Sari, M. Muslimin, A. Franz, and P. Sugiartawan, "Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit dengan Algoritme K-Means," *SINTECH (Science Inf. Technol. J.)*, vol. 5, no. 2, pp. 154–164, 2022, doi: 10.31598/sintechjournal.v5i2.1146.
- [6] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *J. Buana Inform.*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [7] S. V. Darshan, "Automated Diagnosis and Cataloguing of Foliar Disease in Apple Trees using Ensemble of Deep Neural Networks," *Int. Res. J. Eng. Technol.*, no. May, pp. 4230–4237, 2020, [Online]. Available: [www.irjet.net](http://www.irjet.net)
- [8] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [9] A. Rahmawati, M. Akbar, and D. Nurdiansyah, "Klasifikasi Tingkat Kematangan Pada Buah Kelapa Sawit Berbasis Deep Learning," vol. 4, pp. 1064–1073, 2025.
- [10] I. Afandy, B. N. Ahmad, and M. R. Amartharizqi, "Klasifikasi Kematangan Sawit Menggunakan Metode Convolutional Neural Network (CNN) Dengan Transfer Learning Xception," *J. Ilm. Teknol. Inf. dan Robot.*, vol. 6, no. 2, pp. 88–98, 2024, doi: 10.33005/jifti.v6i2.158.
- [11] R. Triyogi, R. Magdalena, and B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network Deep Learning," *J. Nas. SAINS dan Tek.*, vol. 1, no. 1, pp. 22–27, 2023, doi: 10.25124/jnst.v1i1.6732.
- [12] M. S. Muna, Y. Setiyo, I. P. S. Wirawan, M. Syarovy, and G. H. Jaya, "Klasifikasi Kematangan Buah Kelapa Sawit Menggunakan Model Yolov8 Berbasis Deep Learning," *J. Agric. Biosyst. Eng. Res.*, vol. 6, no. 1, p. 50, 2025, doi: 10.20884/1.jaber.2025.6.1.15953.
- [13] A. chandra Saputra and E. D. Oktaviyani, "Rancang Bangun Sistem Deteksi Kematangan Buah Kelapa Sawit Berdasarkan Deteksi Warna Menggunakan Algoritma K-Nn," *J. Teknol. Inf. J. Keilmuan dan Apl. Bid. Tek. Inform.*, vol. 7, no. 2, pp. 222–229, 2023, doi: 10.47111/jti.v7i2.9232.
- [14] I. M. Kamal, S. Mochammad, L. Nurahmi, A. Natawijaya, and M. Kalili, "An Ordinal Dataset for Ripeness Level Classification in Oil Palm Fruit Quality Grading." [Online]. Available: <https://data.mendeley.com/datasets/424y96m6sw/1>
- [15] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep



- Learning,” *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [16] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [17] S. K. Parinduri, R. Rosnelly, A. Purnama, A. Sihotang, M. Chintya, and U. P. Utama, “Perbandingan Algoritma Support Vector Machine Dan K-Nearest Neighbors Pada Kematangan Buah Sawit,” vol. 13, no. 2, pp. 147–155, 2023.