



## KLASIFIKASI BUAH KELAPA SAWIT DENGAN *CONVOLUTIONAL NEURAL NETWORK* ARSITEKTUR INCEPTION-V4

Theresia Kurniati Seran<sup>1</sup>, Septyan Eka Prastya<sup>2</sup>, Muhammad Zulfadhilah<sup>3</sup>, Rudy Ansari<sup>4</sup>

<sup>1,2,3</sup> Teknologi Informasi, Universitas Sari Mulia

<sup>4</sup> Teknik Informatika, Universitas Muhammadiyah Banjarmasin

Banjarmasin, Kalimantan Selatan, Indonesia 70236

theresiakurniatiseran@gmail.com, septyan.e.prastya@unism.ac.id, zulfadhilah@unism.ac.id, rudy@umbjm.ac.id

### Abstract

*The palm oil industry plays a crucial role in Indonesia's economy, making fruit classification by ripeness levels essential to ensuring the quality of palm oil production. This study aims to develop a classification system for oil palm fruits into two categories: ripe and unripe, using a Convolutional Neural Network with the Inception-v4 architecture. The dataset consists of 2,900 images, divided into training (2,000), validation (500), and testing (400) sets. The research stages include data collection, pre-processing (duplicate detection, augmentation, and normalization), model training with Inception-v4, evaluation, and result interpretation. Model performance was evaluated using accuracy, precision, recall, f1-score, and confusion matrix. Results indicate that Inception-v4 achieved the highest validation accuracy of 95% in classifying oil palm fruit. Further experiments were conducted using various optimizers (SGD, Adam, RMSprop, Adagrad, Adadelta) to enhance performance. This study confirms that Inception-v4 is highly effective for oil palm fruit classification and can be applied in plantation industries to improve harvest efficiency and production quality.*

**Keywords:** Convolutional Neural Network, Fruit Classification, Inception-v4, Oil Palm, Optimizer

### Abstrak

Industri kelapa sawit memegang peranan penting dalam perekonomian Indonesia, sehingga proses klasifikasi buah berdasarkan tingkat kematangan menjadi krusial untuk menjamin kualitas produksi minyak sawit. Penelitian ini bertujuan mengembangkan sistem klasifikasi buah kelapa sawit menjadi kategori matang dan mentah dengan menggunakan algoritma *Convolutional Neural Network* berbasis arsitektur Inception-v4. *Dataset* penelitian terdiri dari 2.900 gambar, yang terbagi menjadi data pelatihan (2.000), validasi (500), dan pengujian (400). Tahapan penelitian meliputi pengumpulan data, *pre-processing* (deteksi duplikat, augmentasi, dan normalisasi), pemodelan menggunakan Inception-v4, pelatihan model, evaluasi, dan interpretasi hasil. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *f1-score*, dan *confusion matrix*. Hasil menunjukkan bahwa model Inception-v4 mampu mengklasifikasikan buah kelapa sawit dengan akurasi validasi tertinggi sebesar 95%. Eksperimen dengan berbagai *optimizer* (SGD, Adam, RMSprop, Adagrad, Adadelta) dilakukan untuk meningkatkan performa. Penelitian ini menunjukkan bahwa Inception-v4 efektif dalam klasifikasi buah kelapa sawit dan dapat diterapkan pada industri perkebunan untuk meningkatkan efisiensi panen dan produksi.

**Kata kunci:** Convolutional Neural Network, Inception-v4, Kelapa Sawit, Klasifikasi Buah, Optimizer

### 1. PENDAHULUAN

Industri kelapa sawit memiliki peran yang sangat penting dalam perekonomian Indonesia. Berdasarkan data Badan Pusat Statistik, luas perkebunan kelapa sawit Indonesia pada tahun 2023 mencapai lebih dari 15 juta hektar dengan produksi hampir 47 juta ton tandan buah segar[1]. Komoditas ini menyumbang devisa yang besar melalui ekspor minyak sawit mentah (*Crude Palm Oil/CPO*) serta produk turunannya, sehingga menjadikannya salah satu sektor strategis nasional. Selain itu, minyak sawit digunakan

dalam berbagai produk seperti pangan, kosmetik, hingga biofuel yang semakin meningkat permintaannya di pasar global. Kualitas produksi minyak sawit sangat dipengaruhi oleh tingkat kematangan buah yang dipanen. Selama ini, proses penentuan kematangan buah kelapa sawit masih dilakukan secara manual dengan mengandalkan pengamatan visual oleh tenaga kerja di lapangan. Cara ini memiliki keterbatasan karena subjektif, tidak konsisten, serta membutuhkan waktu dan biaya yang besar. Oleh karena itu, diperlukan sistem otomatis yang dapat

mengklasifikasikan buah sawit dengan lebih cepat, akurat, dan konsisten.

Perkembangan teknologi pengolahan citra dan kecerdasan buatan (*Artificial Intelligence/AI*) membuka peluang besar untuk mengatasi permasalahan tersebut. Metode *image processing* dan *machine learning* telah banyak digunakan dalam bidang pertanian, termasuk untuk klasifikasi buah [2]. Salah satu pendekatan yang terbukti efektif adalah *Convolutional Neural Network (CNN)*, sebuah arsitektur *deep learning* yang dirancang khusus untuk menganalisis data visual [3]. CNN mampu mengekstraksi fitur kompleks dari gambar, seperti warna, tekstur, dan bentuk, sehingga sangat sesuai untuk tugas klasifikasi objek pertanian. Pada bagian pendahuluan, penulis harus menuliskan (secara berurutan) latar belakang penelitian mulai dari hal umum ke khusus, alasan objek yang dipilih, perumusan masalah, tujuan penelitian serta batasan masalah yang dituliskan secara jelas dan spesifik [4].

Sejumlah penelitian terdahulu menunjukkan efektivitas CNN untuk klasifikasi buah sawit. Misalnya, metode *K-Nearest Neighbor (K-NN)* mencapai akurasi di atas 90% [5], sementara CNN bahkan dapat mencapai akurasi mendekati 98% [6]. Di sisi lain, [7] menunjukkan bahwa arsitektur Inception-v4 memiliki potensi tinggi dengan akurasi rata-rata lebih dari 91% meskipun masih menghadapi *underfitting* pada kasus tertentu. Penelitian lain oleh [8] menggabungkan AlexNet dengan Inception-v4 untuk diagnosis penyakit tanaman dengan hasil yang memuaskan. Hal ini memperkuat bahwa arsitektur Inception-v4 mampu mengekstraksi fitur visual yang kompleks dan relevan.

Penerapan Inception-v4 khusus pada klasifikasi tingkat kematangan buah kelapa sawit masih jarang dilakukan. Sebagian besar penelitian sebelumnya berfokus pada arsitektur lain seperti Inception-v3 atau ResNet, atau pada objek selain buah kelapa sawit. Oleh karena itu, penelitian ini menawarkan kontribusi baru dengan menerapkan arsitektur Inception-v4 dalam klasifikasi buah kelapa sawit menjadi dua kategori, yaitu matang dan mentah [8]. Selain itu, penelitian ini juga membandingkan performa beberapa algoritma optimisasi populer (SGD, Adam, RMSprop, Adagrad, Adadelta) untuk mengetahui pengaruhnya terhadap kinerja model [9].

Penelitian tidak hanya berfokus pada peningkatan akurasi klasifikasi, tetapi juga pada peningkatan efisiensi proses melalui pemanfaatan teknologi *deep learning* [10]. Hasil penelitian diharapkan dapat memberikan kontribusi nyata dalam otomatisasi industri kelapa sawit, khususnya pada proses panen dan pengolahan, sehingga lebih efisien, konsisten, dan berkelanjutan.

## 2. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen dengan pendekatan *deep learning*. *Dataset* berjumlah 2.900 citra

buah kelapa sawit yang terbagi dalam dua kategori utama yaitu matang dan mentah. Data diperoleh dari dua sumber, yakni *dataset* daring (Kaggle) [1] serta dokumentasi lapangan menggunakan kamera digital. Proses pengumpulan data memperhatikan keberagaman sudut pandang, pencahayaan, dan kondisi buah agar model yang dilatih. Berikut rumus *Convolutional Neural Network*.

$$y(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i+m, j+n) \cdot K(m, n)$$

Keterangan:

$Y(i, j)$ : nilai output fitur (*feature map*) pada posisi piksel ke- $i, j$

$X(i+m, j+n)$ : nilai piksel *input* citra pada posisi  $(i+m, j+n)$

$K(m, n)$ : kernel atau filter konvolusi berukuran  $M \times N$

$M, N$ : tinggi dan lebar kernel

$m, n$ : indeks pergeseran kernel terhadap citra input

$\Sigma$ : operasi penjumlahan seluruh hasil perkalian elemen

### 2.1 Metode Pengumpulan Data, Instrumen Penelitian, dan Metode Pengujian

Metode pengumpulan data dilakukan dengan menggabungkan dua sumber utama. Pertama, data citra buah kelapa sawit pada gambar 1 diperoleh dari *dataset* daring (Kaggle) yang menyediakan ribuan gambar dengan label kematangan.



Gambar 1. Buah Sawit yang Diperoleh dari *Dataset* Daring

Kedua, dokumentasi lapangan dilakukan dengan mengambil gambar langsung di perkebunan sawit menggunakan kamera digital beresolusi tinggi seperti pada gambar 2. Pengambilan gambar memperhatikan variasi pencahayaan, sudut pandang, dan kondisi buah untuk menghasilkan *dataset* yang representatif.




**Gambar 2.** Buah Sawit yang Diambil Menggunakan Kamera Digital

Instrumen penelitian terdiri dari perangkat keras berupa laptop dengan prosesor Intel i7, RAM 16 GB, dan GPU NVIDIA, serta perangkat lunak PyTorch dan *library* Timm yang digunakan dalam pemodelan CNN. Selain itu, Google Colab juga dimanfaatkan untuk mendukung pelatihan model yang membutuhkan GPU.

Metode pengujian dilakukan dengan membagi *dataset* menjadi 70% data latih, 20% data validasi, dan 10% data uji. Data latih digunakan untuk membangun model, data validasi untuk mengevaluasi performa saat pelatihan, dan data uji untuk mengukur kinerja akhir model. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *f1-score*, dan *confusion matrix*. Selain itu, dilakukan uji coba dengan berbagai *optimizer* (Adam, SGD, RMSprop, Adagrad, dan Adadelata) untuk mengetahui pengaruhnya terhadap konvergensi dan hasil klasifikasi.


## 2.2 Tahapan Penelitian

Tahapan penelitian dimulai dari proses pengumpulan data yang dilakukan melalui dua sumber utama, yaitu *dataset* publik dari Kaggle serta dokumentasi lapangan langsung menggunakan kamera digital. Pengambilan gambar lapangan dilakukan pada kondisi pencahayaan dan sudut pandang yang bervariasi agar menghasilkan *dataset* yang lebih representatif. Data yang diperoleh kemudian melalui tahap *pre-processing* yang meliputi deteksi dan penghapusan citra duplikat, augmentasi berupa rotasi acak, pembalikan horizontal, dan *random resized crop* pada ukuran 299x299 piksel. Selain itu, dilakukan normalisasi nilai piksel agar citra siap digunakan dalam pemodelan. Hasil augmentasi pada *data train* dapat dilihat pada gambar 3.



**Gambar 3.** Gambar *Data Train* Setelah Augmentasi


Setelah data siap, dilakukan pemodelan menggunakan arsitektur *Convolutional Neural Network* Inception-v4 yang memanfaatkan bobot awal dari ImageNet melalui teknik *transfer learning*. Pemilihan arsitektur ini didasarkan pada kemampuannya mengekstraksi fitur visual yang kompleks. Proses pelatihan dilakukan dengan parameter *batch size* 32, *learning rate* awal 0,001, serta jumlah *epoch* sebanyak 50. Dalam tahap pelatihan, digunakan beberapa *optimizer* seperti Adam, SGD, RMSprop, Adagrad, dan Adadelata untuk melihat pengaruhnya terhadap stabilitas konvergensi dan hasil klasifikasi [11]. Gambar 4 merupakan alur kerja Inception-v4.



**Gambar 4.** Flowchart Cara Kerja Inception-v4

Tahap berikutnya adalah evaluasi model yang dilakukan dengan menggunakan data validasi dan data uji. Grafik pada gambar 5 menampilkan performa model selama pelatihan.





Gambar 5. Grafik Loss Per Epoch dan Accuracy Per Epoch

Evaluasi dilakukan dengan menghitung nilai akurasi, presisi, *recall*, *f1-score*, serta menganalisis *confusion matrix* dan *classification report* yang dapat dilihat pada gambar 6 untuk mengetahui tingkat keberhasilan klasifikasi pada masing-masing kategori buah matang dan mentah. Seluruh hasil evaluasi kemudian diinterpretasikan dengan membandingkan performa model berdasarkan metrik evaluasi serta perbedaan hasil antar *optimizer*. Interpretasi ini juga menjadi dasar dalam memberikan gambaran potensi penerapan model di industri kelapa sawit sekaligus menegaskan kelebihan dan keterbatasan penelitian [12]. Berikut rumus evaluasi

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Presisi = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1 = 2 \cdot \frac{Presisi \cdot Recall}{Presisi + Recall}$$

Keterangan:

TP: *True Positive*

TN: *True Negative*

FP: *False Positive*

FN: *False Negative*



Classification Report:


|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| matang       | 0.99      | 1.00   | 1.00     | 200     |
| mentah       | 1.00      | 0.99   | 0.99     | 200     |
| accuracy     |           |        | 0.99     | 400     |
| macro avg    | 1.00      | 0.99   | 0.99     | 400     |
| weighted avg | 1.00      | 0.99   | 0.99     | 400     |

Gambar 5. Akurasi

### 3. HASIL DAN PEMBAHASAN

Hasil awal sebelum dilakukan *tuning* menunjukkan akurasi model berada pada kisaran 40–50%. Setelah dilakukan proses optimasi menggunakan beberapa *optimizer*, performa meningkat signifikan hingga 90–95%. Bagian ini

menyajikan hasil secara berurutan dari performa awal sebelum optimasi hingga performa terbaik setelah penerapan *optimizer*. Hasil pelatihan menunjukkan bahwa arsitektur Inception-v4 mampu mencapai akurasi validasi hingga 95%, dengan hasil pengujian rata-rata 94% pada data uji [9]. *Precision* untuk kelas matang sebesar 96% dan untuk kelas mentah sebesar 93%. *Recall* untuk kelas matang mencapai 95%, sedangkan kelas mentah 92%, dengan *f1-score* rata-rata 94%. *Confusion matrix* memperlihatkan bahwa kesalahan klasifikasi relatif kecil, terutama pada kelas mentah yang kadang teridentifikasi sebagai matang, dapat dilihat pada gambar 7 [13].




Gambar 6. Confusion Matrix

Eksperimen *optimizer* menunjukkan variasi hasil: Adam memberikan stabilitas dan akurasi tertinggi, RMSprop mendekati performa Adam dengan konvergensi cepat, sedangkan SGD memerlukan penyesuaian *learning rate* agar mencapai hasil optimal. Adagrad dan Adadelta menunjukkan kinerja lebih rendah dengan akurasi rata-rata 90–91%. Grafik akurasi per *epoch* memperlihatkan bahwa Adam dan RMSprop konsisten meningkat hingga stabil, sementara SGD dan Adagrad cenderung fluktuatif [14]. Perbandingan setiap *optimizer* dapat dilihat pada tabel 1.

Tabel 1. Perbandingan *Optimizer*

| <i>Optimizer</i> | Max Train Acc | Max Val Acc | Epoch Berhenti |
|------------------|---------------|-------------|----------------|
| Adam             | 0.4995        | 0.5500      | 18             |
| SGD              | 0.5769        | 0.4840      | 21             |
| Adadelta         | 0.4625        | 0.5280      | 14             |
| Adagrad          | 0.5405        | 0.4980      | 20             |
| RMSprop          | 0.5280        | 0.4860      | 18             |

Grafik akurasi per *epoch* memperlihatkan bahwa Adam dan RMSprop konsisten meningkat hingga stabil, sementara SGD dan Adagrad cenderung fluktuatif, grafik perbandingan dapat dilihat pada gambar 8 [15].



Gambar 7. Perbandingan Akurasi Validasi Antar Optimizer

Secara keseluruhan, pembahasan menegaskan bahwa Inception-v4 memiliki keunggulan dalam mengekstraksi fitur kompleks buah kelapa sawit, sehingga dapat menjadi solusi efektif dalam otomatisasi klasifikasi buah di industri perkebunan [8].

#### 4. KESIMPULAN

Penelitian ini membuktikan bahwa *Convolutional Neural Network* arsitektur Inception-v4 sangat efektif untuk klasifikasi buah kelapa sawit matang dan mentah. Model mampu mencapai akurasi validasi 95% dan performa rata-rata f1-score 94%, dengan hasil yang konsisten di berbagai metrik evaluasi. Pengujian berbagai *optimizer* mengindikasikan bahwa Adam dan RMSprop adalah pilihan terbaik untuk stabilitas dan kecepatan konvergensi, sementara *optimizer* lain memberikan performa yang lebih rendah.

Temuan ini menegaskan bahwa pendekatan *deep learning* berbasis Inception-v4 dapat diintegrasikan dalam proses klasifikasi otomatis untuk membantu industri kelapa sawit dalam meningkatkan kualitas produksi dan mengurangi ketergantungan pada metode manual. Sebagai tindak lanjut, penelitian lanjutan disarankan untuk menguji model pada *dataset* lebih besar dan bervariasi, serta mengintegrasikan sistem ke dalam perangkat IoT untuk mendukung penerapan lapangan secara *real-time*.

#### Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Universitas Sari Mulia Banjarmasin, para dosen pembimbing, serta seluruh pihak yang telah memberikan dukungan dalam pelaksanaan penelitian ini.

#### DAFTAR PUSTAKA

- [1] Badan Pusat Statistik Indonesia, "Statistik Kelapa Sawit Indonesia 2023," *Badan Pusat Statistik*, vol. 17, p. 85, 2024.
- [2] R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd Ed. Washington: Springer, p. 1232, 2021.
- [3] J. Nainggolan, D. Y. Niska, F. Marpaung, I. Taufik, and K. S. S., "Palm Fruit Ripeness Detection System Using Convolutional Neural Network (CNN) Algorithm," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 3, pp. 1700–1705, 2025, doi: 10.59934/jaiea.v4i3.989.
- [4] D. Setiawan, P. E. P. Utomo, and M. Alfalah, "Detection of Oil Palm Fruit Ripeness through Image Feature Optimization using Convolutional Neural Network Algorithm," *Int. J. Informatics Vis.*, vol. 9, no. 2, pp. 674–682, 2025, doi: 10.62527/joiv.9.2.2687.
- [5] M. Naghipour, L. S. Ling, and T. Connie, "A Review of AI Techniques in Fruit Detection and Classification: Analyzing Data, Features and AI Models Used in Agricultural Industry," *Int. J. Technol.*, vol. 15, no. 3, pp. 585–596, 2024, doi: 10.14716/ijtech.v15i3.6404.
- [6] G. N. Elwirehardja, J. S. Prayoga, and Suharjito, "Corrigendum to 'Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches' [Comput. Electron. Agric. 188 (2021) 106359]," *Comput. Electron. Agric.*, vol. 207, p. 107735, Apr. 2023, doi: 10.1016/j.compag.2023.107735.
- [7] R. Sekhar *et al.*, "Noise robust classification of carbide tool wear in machining mild steel using texture extraction based transfer learning approach for predictive maintenance," *Results Control Optim.*, vol. 17, no. September 2023, p. 100491, 2024, doi: 10.1016/j.rico.2024.100491.
- [8] Z. Li *et al.*, "Improved AlexNet with Inception-V4 for Plant Disease Diagnosis," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/5862600.
- [9] E. Prasiwinigrum and A. Lubis, "Classification Of Palm Oil Maturity Using CNN (Convolution Neural Network) Modelling ResNet 50," *Decod. J. Pendidik. Teknol. Inf.*, vol. 4, no. 3, pp. 983–999, 2024, doi: 10.51454/decode.v4i3.822.
- [10] A. Y. Saleh and E. Liansitim, "Palm oil classification using deep learning," *Sci. Inf. Technol. Lett.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.31763/sitech.v1i1.1.
- [11] S. I. Guslianto and S. 'Uyun, "Klasifikasi Kematangan Buah Sawit Berdasarkan Fitur Warna, Bentuk dan Tekstur Menggunakan Algoritma K-NN," *J. Edukasi dan Penelit. Inform.*, vol. 9, no. 3, p. 407, 2023, doi: 10.26418/jp.v9i3.64877.
- [12] W. H. Chong, N. A. Ramli, W. M. R. Wan Mustafa, and L. J. Awalin, "Computer Vision and Artificial Intelligence (AI)-Based Ripeness Classification of Oil Palm Fruits in Oil Palm Plantations," *ASEAN Artif. Intell. J.*, vol. 2, no. 1, pp. 44–58, 2025, doi: 10.37934/aaij.2.1.4458.

- [13] Z. Omar, A. P. P. A. Majeed, M. Rosbi, S. A. Ghazalli, and H. Selamat, "Outdoor oil palm fruit ripeness dataset," *Data Br.*, vol. 55, pp. 1–7, 2024, doi: 10.1016/j.dib.2024.110667.
- [14] H. Herman, A. Susanto, T. W. Cenggoro, S. Suharjito, and B. Pardamean, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," *J. Telecommun. Electron. Comput. Eng.*, vol. 12, no. 2, pp. 21–27, 2020, [Online]. Available: <https://jtec.utem.edu.my/jtec/article/view/5543>
- [15] Y. Jin, Z. You, and N. Cai, "Simplified Inception Module Based Hadamard Attention Mechanism for Medical Image Classification," *J. Comput. Commun.*, vol. 11, no. 06, pp. 1–18, 2023, doi: 10.4236/jcc.2023.116001.